

UNIVERSIDADE ESTADUAL DE CAMPINAS - UNICAMP
FACULDADE DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO
DEPARTAMENTO DE COMPUTAÇÃO E AUTOMAÇÃO

ANÁLISE HIERÁRQUICA DE IMAGENS ATRAVÉS DA ÁRVORE DOS LAGOS CRÍTICOS

Autor: **Marco Antonio Garcia de Carvalho**
Orientador: **Prof. Roberto de Alencar Lotufo, Ph.D.**
Co-orientador: **Prof. Michel Couprie, Ph.D.**

Tese de Doutorado apresentada à Faculdade de Engenharia Elétrica e de Computação como parte dos requisitos para obtenção do título de Doutor em Engenharia Elétrica. Área de concentração: **Engenharia de Computação.**

Fevereiro de 2004
Campinas, SP - Brasil

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

C253a Carvalho, Marco Antonio Garcia de
 Análise hierárquica de imagens através da árvore dos
 lagos críticos / Marco Antonio Garcia de Carvalho.--
 Campinas, SP: [s.n.], 2004.

 Orientadores: Roberto de Alencar Lotufo e Michel
 Couprie.

 Tese (Doutorado) - Universidade Estadual de
 Campinas, Faculdade de Engenharia Elétrica e de
 Computação.

 1. Morfologia matemática. 2. Processamento de
 imagens – Técnicas digitais. 3. Árvores – Teoria dos
 grafos. I. Lotufo, Roberto de Alencar. II. Couprie,
 Michel. III. Universidade Estadual de Campinas.
 Faculdade de Engenharia Elétrica e de Computação. IV.
 Título.

UNIVERSIDADE ESTADUAL DE CAMPINAS - UNICAMP
FACULDADE DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO
DEPARTAMENTO DE COMPUTAÇÃO E AUTOMAÇÃO

ANÁLISE HIERÁRQUICA DE IMAGENS ATRAVÉS DA ÁRVORE DOS LAGOS CRÍTICOS

Autor: **Marco Antonio Garcia de Carvalho**
Orientador: **Prof. Roberto de Alencar Lotufo, Ph.D.**
Co-orientador: **Prof. Michel Couprie, Ph.D.**

Tese de Doutorado apresentada à Faculdade de Engenharia Elétrica e de Computação como parte dos requisitos para obtenção do título de Doutor em Engenharia Elétrica. Área de concentração: **Engenharia de Computação.**

Banca Examinadora

Roberto de Alencar Lotufo, Ph.D.	DCA/FEEC/UNICAMP
Gabriela Castellano, Ph.D.	DCA/FEEC/UNICAMP
Clésio Luis Tozzi, Ph.D.	DCA/FEEC/UNICAMP
João Baptista T. Yabu-Uti, Ph.D.	DECOM/FEEC/UNICAMP
Arnaldo de Albuquerque Araújo, Ph.D.	DCC/UFGM
Roberto Marcondes César Junior, Ph.D.	IME/USP

Fevereiro de 2004
Campinas, SP - Brasil

Resumo

CARVALHO, M. A. G. **Análise Hierárquica de Imagens através da Árvore dos Lagos Críticos.** Campinas: DCA / FEEC / UNICAMP, 2003. (Tese de Doutorado)

Segmentação de uma imagem consiste em separar a imagem em regiões segundo determinados critérios e a finalidade da aplicação. Recentes trabalhos na área de processamento de imagens utilizam uma estratégia de segmentação denominada de *segmentação multiescala* ou *hierárquica*. A segmentação multiescala fornece uma família de partições de uma imagem, apresentando-a em diversos níveis de resolução.

Este trabalho estuda uma representação multiescala de imagens, chamada de Árvore dos Lagos Críticos (ALC), que fornece um conjunto de partições aninhadas de uma imagem. A Árvore dos Lagos Críticos é definida no âmbito da Transformada Watershed, a tradicional ferramenta da Morfologia Matemática para a realização de segmentação de imagens. Neste trabalho a ALC foi modelada com o auxílio de árvores hierárquicas.

São apresentadas soluções baseadas em ALC para três tipos de problemas em especial: (i) Segmentação espaço-temporal e casamento hierárquico em seqüências de imagens de Ressonância Magnética do ventrículo esquerdo do coração; e (ii) Segmentação de imagens de uma classe de fungos conhecida como leveduras, baseada na análise do espaço de escalas.

Palavras-chave: Morfologia matemática, Watershed, Árvore dos lagos críticos, Segmentação multiescala, Casamento de imagens

Abstract

CARVALHO, M. A. G. **Hierarchical Image Analysis Through the Tree of Critical Lakes.** Campinas: DCA / FEEC / UNICAMP, 2003. (PhD Thesis)

Image segmentation consists of separating an image into regions according to some criteria and to the application finality. Recent publications in the image processing domain make use of a segmentation strategy called *multiscale* or *hierarchical segmentation*. The multiscale segmentation provides a family of partitions of an image, presenting it at several levels of resolution.

This work studies a multiscale image representation called *Tree of the Critical Lakes* (TCL), that provides an set of nested partitions of an image. The Tree of the Critical Lakes is defined from the Watershed Transform, the traditional tool of Mathematical Morphology in image segmentation operations. Here, the TCL was modelled through hierarchical trees.

Solutions based on TCL's are presented, specially, for three groups of problems: (i) Spatio-temporal segmentation and hierarchical matching of the magnetic ressonance image sequences (left ventricle); and (ii) Scale-space segmentation of the yeast cells images, a fungi group.

Keywords: Mathematical morphology, watershed, tree of the critical lakes, multiscale segmentation, image matching

À minha família

Meus pais Francisco e Francisca

Meus irmãos Ivalder, Simone e Adriana

Agradecimentos

Após 4 anos de trabalho, me sinto feliz em ter concluído mais uma etapa em minha formação acadêmica. Me sinto mais feliz ainda de ter realizado um sonho de adolescência que era ter a oportunidade de morar na França na etapa sanduíche do trabalho, um país que habitava em minha cabeça desde a época do ginásio.

É imprescindível o apoio de diversas pessoas em um projeto de vida como este e me sinto não na obrigação de agradecer, mas sim de expressar de maneira espontânea o meu reconhecimento e gratidão pela preciosa colaboração e incentivo.

Agradeço especialmente à minha família, que me apoiou incondicionalmente desde a minha saída de Natal para a realização do mestrado na Unicamp, no retorno à Campinas em 1999 para a realização do doutorado e deu especial atenção durante minha estada na França. Obrigado aos meus pais Francisco e Francisca, e aos meus irmãos, Ivalder, Simone, Adriana e Neves, que sempre me incentivaram a concretizar este sonho, mesmo sem entender o que realmente eu fazia. Agradeço também aos parentes pelas palavras de estímulo e apoio.

À Kelly, minha namorada, sou grato pela sua paciência, incentivo e amor. Sua dedicação ao trabalho de mestrado também espelhou em diversos momentos o sentimento de perseverança de alcançar o objetivo traçado. Sua presença transmitiu-me conforto e segurança, especialmente no período da etapa sanduíche.

Ao meu orientador, Prof. Roberto de Alencar Lotufo, sou grato pela sua compreensão, incentivo, cobranças e pelo compartilhamento de sua sabedoria. Foram 4 anos de trabalho em conjunto, um verdadeiro aprendizado da metodologia científica. Sua metodologia de trabalho e acompanhamento dos orientandos tornou-se uma referência para mim.

Agradeço ao Prof. Michel Couprie pela direção dos trabalhos durante

minha permanência no estágio sanduíche no Groupe ESIEE (*École Supérieure d'Ingénieurs en Électrotechnique et Électronique*) / Paris. As conversas sempre eram muito produtivas e o rigor matemático em muito me inspirou nesta tese e norteará a minha vida acadêmica.

Um Muito Obrigado aos colegas de trabalho Well, Francisco, Franklin, Jane, Ricardo, Alex, Rangel e Romaric. Muitas vezes dividimos dúvidas e conquistas neste período, além das discussões esclarecedoras em reuniões, nos corredores e no LCA.

Sou muito grato aos funcionários e professores do DCA e FEEC, pelo apoio operacional. Em especial, agradeço à secretária do DCA, Carmen, pela sua paciência e presteza. Também sou grato aos funcionários da Biblioteca Central que em diversos momentos facilitaram o acesso a referências bibliográficas desta tese.

No início do doutorado, estava ligado ao DECOM sob a supervisão do Prof. João Baptista Yabu-uti. Agradeço a sua compreensão e incentivo no processo de troca de departamento e orientação.

Agradeço aos grandes amigos, companheiros e parceiros desta caminhada: os amigos do LCA (Bicho, Maria, Isla, Osmar, Leandro, Andréa e Adriana, Nicola, Rodrigo, Naur, Gonzaga, Paulinho, Vinícius, Raquel, Alex Peru, Fábio, Mercedes, Ivana, Marina, Virgínia e Gisele, Edgard, Ivete, Cláudio, Alfredo), as pessoas que conheci nas diversas disciplinas realizadas e, os colegas da musculação da FEF e da Unicamp (Juliana, Adriana, Neiva, Betis, Betânia, Marcus, Luciano, Cornélius, Douglas, Sílvia, Gabi, Débora, Inka), os companheiros do DECOM e DMO que vieram de Natal (Hélcio, Fábio, Marcelo, Luís Carlos, Álvaro, Patrocínio), colegas do DT e parceiros do forró (Edilson, Márcia, Danitchela, Tatiane). Todos eles contribuíram imensamente nesta tese e tornaram a minha vida mais plena e alegre. Os amigos da França (Sílvia, Tatiane, Yukiko, Cristophe, Delphine, Cedric, Rossany, Alan, Charbel, Gamal, Daoud, Linda, Cristophe, Francisco, Xavier, Benoit) foram fundamentais nos 10 meses de Paris. Os churrascos que fiz em minha casa, com comida japonesa, libanesa, venezuelana e francesa levaram-nos a uma convivência amigável que deixou saudades.

Desde 2000 participo do Coral Unicamp Zíper na Boca. Vivi momentos bastante agradáveis nos ensaios, viagens, apresentações e encontros dos integrantes do coro. Eles contribuíram fortemente na melhoria da qualidade de vida em Campinas.

Agradeço aos amigos da turma de 94, professores (em especial ao Prof. Adrião) e funcionários da Universidade Federal do Rio Grande do Norte —

UFRN, pela colaboração na minha formação acadêmica. Obrigado também aos colegas professores e à Direção da Universidade Potiguar (UnP), em Natal.

Obrigado aos companheiros de república do início do doutorado (Eduardo, Marcelo 1, Fábio e Adilson) que me acolheram prontamente na minha vinda súbita à Campinas e pela convivência diária em nossa casa.

Sem suporte financeiro não seria possível a conclusão desta tese. Portanto, agradeço ao CNPq (Processo no. 147460/1999-9) e à CAPES pelos recursos humanos e materiais dispendidos nos 4 anos de trabalho. O convênio CAPES / COFECUB de processo no. 396/02 auxiliou na etapa sanduíche e sou grato por isso. Agradeço também à *SDC Morphology* pela permissão de uso da sua *toolbox* de morfologia matemática voltada para o software *MATLAB*.

Acima de tudo, AGRADEÇO A DEUS, pelo dom da vida e a saúde física, mental e espiritual que sempre me acompanharam neste período.

Conteúdo

Conteúdo	13
Lista de Figuras	15
1 Introdução	1
1.1 Motivação	1
1.2 Objetivos	3
1.3 Organização da Tese	3
2 Segmentação de imagens	5
2.1 Introdução	5
2.2 Watershed	6
2.2.1 Definições básicas	6
2.2.2 Watershed baseado na simulação de imersão	8
2.3 Segmentação Multiescala	11
3 Representação Hierárquica de imagens	15
3.1 Introdução	15
3.2 Grafos - Notações e definições	16
3.3 Outras estruturas de árvore na representação de imagens	17
3.4 Árvore dos lagos críticos	20
3.4.1 Construção da ALC via Árvore Geradora Mínima	22
3.4.2 Representação da ALC	25
3.4.3 Construção de partições	26
3.4.4 Operações hierárquicas locais	26
3.4.5 Segmentação temporal do ventrículo esquerdo do co- ração com base em operações hierárquicas locais	31

3.5	Segmentação multiescala através da avaliação dos contornos de uma imagem	34
3.5.1	Introdução	34
3.5.2	Lista de inundação	36
3.5.3	Árvore dos lagos críticos	39
3.5.4	Árvore geradora mínima	40
3.5.5	Resultados e discussões	41
4	Casamento Hierárquico de imagens	45
4.1	Introdução	45
4.2	Caracterização do problema de correspondência entre grafos .	47
4.3	O grafo associativo	48
4.4	O clique máximo	51
4.5	Aplicação na perseguição do volume de sangue do ventrículo esquerdo em imagens de ressonância magnética	52
4.5.1	Introdução	52
4.5.2	Grafo associativo e determinação do clique	53
4.5.3	Experimentos e resultados	56
5	Análise do espaço de escalas	63
5.1	Introdução	63
5.2	Paradigmas e propriedades de um espaço de escalas	65
5.3	Segmentação de imagens via análise do espaço de escalas . . .	67
5.3.1	Cálculo dos atributos	67
5.3.2	Análise dos atributos	69
5.3.3	Resultados em imagens	70
5.4	Aplicação na segmentação de leveduras	71
5.4.1	Fundamentos	71
5.4.2	Metodologia	75
5.4.3	Experimentos e Resultados	76
6	Conclusão	85
6.1	Contribuições desta tese	85
6.2	Perspectivas	87
	Referências bibliográficas	91

Lista de Figuras

2.1	Tipos de vizinhança ao <i>pixel</i> p , em cinza:(a) vizinhança-4; (b)vizinhança-8.	6
2.2	(a) Exemplos de zonas planas, em preto.	7
2.3	(a) Mínimos Regionais de uma imagem.	7
2.4	(a) Dinâmica de um mínimo.	8
2.5	Visualização de uma imagem:(a) imagem original <i>camera man</i> ; (b) gradiente morfológico de (a); (c) visualização através de um relevo.	9
2.6	Princípio da imersão de uma imagem:(a) imagem original e seus mínimos; (b) criação de barragens; (c) imagem imersa. . .	10
2.7	Diferentes tipos de inundação:(a) e (b) síncrona; (c) e (d) uniforme. São ilustradas as configurações do início da inundação e do primeiro contato entre duas bacias formadas pelos mínimos m_1 e m_2	11
2.8	Construção de uma hierarquia para uma imagem artificial. . .	12
2.9	Exemplo de partições para a imagem <i>camera man</i> . Partições associadas às regiões da imagem: (a) partição com 5 regiões; (b) partição com 10 regiões; (c) partição com 20 regiões. Partições associadas aos contornos das regiões da imagem: (d) partição com 25 regiões; (e) partição com 15 regiões; (f) partição com 2 regiões.	13
3.1	Construção de uma árvore dos componentes: (a) imagem original; (b) I_1 ; (c) I_2 ; (d) I_3 ; (e) I_6 ; (f) árvore completa.	18
3.2	Construção de uma árvore de partição binária.	20
3.3	Formação de um lago crítico em um relevo topográfico.	20
3.4	Construção da árvore dos lagos críticos.	21

3.5	Exemplo de construção da árvore geradora mínima durante o processo de inundação: (a) imagem original; (b) imagem dos mínimos rotulados; (c)-(e) encontro entre bacias; (f) imagem inundada.	23
3.6	Árvore geradora mínima da Figura 3.5(a).	24
3.7	Exemplo de transformação de AGM para ALC via Algoritmo 1: (a) AGM da Figura 3.6; (b)-(d) etapas da transformação e árvore final em (d).	25
3.8	Dendrograma para a Figura 3.7.	26
3.9	Construção de partições a partir da ALC. O limiar T_2 produz uma partição com duas regiões (quadrados pontilhados)	27
3.10	Exemplo de partições aninhadas em diferentes imagens:(a)-(c) imagem <i>escritório</i> ; (d)-(f) imagem <i>mother</i> ; (g)-(i) imagem <i>célula</i>	28
3.11	Operações hierárquicas locais: seleção de uma região do dendrograma.	28
3.12	Operações hierárquicas locais – re-segmentação de uma partição: (a)-(c) re-segmentação da imagem <i>camera man</i> a partir de uma partição com duas regiões e partição com 20 regiões obtidas pelo processo sem re-segmentação; (d)-(f) resegmentação da face do menino na imagem <i>mother</i> a partir de uma partição com 7 regiões e partição com 22 regiões obtidas pelo processo sem re-segmentação.	29
3.13	Operações hierárquicas locais – fusão de regiões da imagem: (a)-(c) exemplo da fusão do fundo na imagem <i>cameran man</i> ; (d)-(f) exemplo da fusão das camisas na imagem <i>mother</i> (<i>frame</i> 0).	30
3.14	Operações hierárquicas locais – seleção de região de interesse via índices hierárquicos: (a) imagem <i>ventr005</i> de um ventrículo esquerdo e (b) ROI selecionada (índice = 900); (c)-(e) exemplo para a imagem <i>alice</i> ; (f)-(h) exemplo para a imagem <i>bush</i>	32
3.15	(a) <i>Frame</i> original <i>ventr028</i> ; (b) classe selecionada após o teste do centróide (passo 4); (c) classe selecionada após teste do nível de cinza (passo 5); (d) <i>ROI</i> e imagem original sobrepostas.	34
3.16	(a) <i>Frame</i> original <i>ventr054</i> ; (b) classe selecionada após o teste do centróide (passo 4); (c) classe selecionada após o teste do nível de cinza (passo 5); (d) <i>ROI</i> e imagem original sobrepostas.	34

3.17	(a) <i>Frames</i> originais <i>ventr019</i> a <i>ventr027</i> ; (b) volume de sangue selecionado após análise hierárquica.	35
3.18	Diagrama esquemático do problema de segmentação através da avaliação dos contornos das regiões de uma imagem.	35
3.19	Exemplo ilustrativo do problema de segmentação através da avaliação dos contornos das regiões de uma imagem: (a) imagem original; (b) imagem dos contornos das regiões, em níveis de cinza; (c) partição de (b) obtida via limiarização (valores de contorno maiores que 1000).	36
3.20	Exemplo de construção da árvore de inundação: (a) imagem original; (b) imagem dos mínimos rotulados; (c)-(d) seqüência de inundação; (e) lista de inundação.	38
3.21	Árvore dos lagos críticos para a imagem original em 3.20(a).	39
3.22	(a) Árvore geradora mínima para a imagem original em 3.20(a); (b) Contornos quantificados para a imagem exemplo estudada.	40
3.23	Exemplo de aplicação da metodologia de ALC para quantificação de bordas: (a) imagem original <i>buro</i> ; (b)-(c) contornos quantificados (imagens em níveis de cinza – normal e sua negação); (d)-(f) resultado da limiarização de (c) para T igual a 100000, 50000 e 2000, respectivamente.	41
3.24	Obtenção de partições de uma imagem via aplicação da metodologia de ALC para quantificação de bordas: (a) imagem original <i>cameraman</i> ; (b)-(d) partições obtidas via limiares 3000, 10000 e 250000, respectivamente, na imagem dos contornos em níveis de cinza.	42
4.1	Exemplo de construção de grafo associativo: (a) Árvore T_1 ; (b) Árvore T_2 ; (c) Grafo associativo entre T_1 e T_2 . Observe que não existe aresta entre os nós (1, 1) e (3, 1), já que no primeiro par o nó 1 de T_1 casa com o nó 1 de T_2 e, por conseguinte, o nó 3 de T_1 não poderia repetir a correspondência com o nó 1 de T_2 . Esse é um exemplo de incompatibilidade relacionado com o princípio da exclusão.	50
4.2	Grafo associativo da Figura 4.1(c) após o uso do critério do caminho orientado.	55

4.3	(a) Seqüência de 8 fatias do ventrículo esquerdo (<i>ventr011-ventr018</i>); (b) seqüência com a região de interesse, definida na primeira fatia e recuperada nas fatias subsequêntes via casamento; (c) imagens (a) e (b) sobrepostas.	57
4.4	(a),(b) Dendrogramas das imagens de ventrículos <i>ventr017</i> e <i>ventr018</i> , respectivamente, e seus (c),(d) grafos associativos para $T_1 = 30$ e $T_1 = 20$. Note a redução da densidade de arestas com a diminuição da tolerância do princípio da proximidade. Infelizmente se torna inviável a ilustração de um grafo associativo sem o uso de critérios tão restritivos, em função da alta densidade de arestas.	58
4.5	(a) Seqüência de 8 fatias do ventrículo esquerdo (<i>ventr029-ventr036</i>); (b) seqüência com a região de interesse, definida na primeira fatia e recuperada nas fatias subsequêntes via casamento; (c) imagens (a) e (b) sobrepostas.	59
4.6	Exemplo de construção de grafo associativo com flexibilização: (a) Árvore T_1 ; (b) Árvore T_2 ; (c) Grafo associativo com flexibilização entre T_1 e T_2 (as arestas tracejadas foram incluídas pelo processo de flexibilização do critério do caminho orientado).	60
4.7	(a)-(b) Fatias originais do ventrículo esquerdo <i>ventr041</i> e <i>ventr042</i> ; (c) Grafo associativo construído sem a flexibilização do critério do caminho orientado; (d)-(e) imagem com as regiões de interesse de (a) e (b), definidas via casamento das imagens originais; (f) imagens (a) e (d) sobrepostas; (g) imagens (b) e (e) sobrepostas.	61
5.1	Representação de um espaço de escalas: estruturas em níveis mais elevados devem ser simplificações delas mesmas em níveis inferiores.	66
5.2	(a) Exemplo de dendrograma e (b) sua representação matricial. Na matriz, as duas primeiras colunas são os rótulos das regiões e classes e a terceira coluna, o índice hierárquico. . . .	68
5.3	Esquema representativo da análise dos atributos. Na imagem à esquerda têm-se várias partições de uma imagem $P_0, P_1, \dots, P_n$, onde as regiões de interesse são as de nível de cinza branco, com formas ovais. Após a análise dos atributos, as regiões de interesse são determinadas (imagem da direita).	70

5.4	Exemplos da segmentação de imagens via análise do espaço de escalas: (a) Imagem original <i>arroz 1</i> ; (b) watershed hierárquico com 70 regiões; (c) watershed hierárquico com 80 regiões; (d) watershed hierárquico com 90 regiões.	72
5.5	Análise do espaço de escalas para a imagem <i>arroz 1</i> : (a) $ST > 500$, $(300 < A < 900)$ e $NC > 110$; (b) $ST > 200$, $(300 < A < 900)$ e $NC > 110$; (c) $ST > 100$, $(200 < A < 900)$ e $NC > 110$; (d) Uma possível solução, binarizada, eliminando-se pedaços não significativos de grãos de arroz.	73
5.6	Resultados obtidos para imagens de leveduras: (a) imagem original; (b) imagem limiarizada com $T > 80$; (c) imagem limiarizada com $T > 100$; (d) imagem limiarizada com $T > 120$; (e) imagem limiarizada com $T > 150$; (f) imagem limiarizada com $T > 170$; (g) Partição com 12 regiões; (h) Partição com 30 regiões; (i) Imagem segmentada pelo método descrito em [39],[41], a partir da imagem binarizada (e); (j) Imagem segmentada via análise do espaço de escalas gerado pela <i>ALC</i>	80
5.7	Seqüência adotada na análise do espaço de escalas: (a) imagem original; (b) dendrograma simplificado de (a); (c) imagem resultante do critério ST ; (d) imagem resultante do critério <i>área</i> aplicado à imagem (c); (e) imagem final das células segmentadas, após utilização do critério de ajuste de elipse.	81
5.8	Variação do <i>tempo de vida</i> na segmentação de células de leveduras: (a) imagem original; (b) imagem com $ST > 430$; (c) imagem com $ST > 600$; (d) imagem com $ST > 710$; (e) imagem com $ST > 1100$; (f) imagem segmentada com critérios ST , <i>área</i> e ajuste de elipse.	82
5.9	(a),(c) Imagens originais de leveduras; (b),(d) células segmentadas.	83
5.10	(a) Imagem original de leveduras; (b) células segmentadas. . .	83

Capítulo 1

Introdução

1.1 Motivação

O desenvolvimento de sistemas artificiais cuja base está relacionada com a habilidade humana de distinguir objetos é um dos principais problemas no domínio da visão computacional. Nesse contexto, a segmentação de imagens é uma tarefa bastante comum às diversas aplicações em processamento de imagens.

Segmentar representa particionar ou delinear objetos de interesse semanticamente definidos. Existem diversas outras definições de segmentação presentes na literatura. Pode-se citar algumas:

- Segmentação é o processo de dividir a imagem em regiões conexas e homogêneas [11],[18];
- O objetivo da segmentação é de reagrupar em regiões elementos que possuem atributos similares [22];
- As técnicas de segmentação têm como finalidade produzir uma partição da imagem tão próxima quanto possível daquela feita pelo olho humano [20].

As aplicações que utilizam segmentação de imagens são bem numerosas. Na compressão de vídeo, por exemplo, a segmentação de imagens tem sido usada para distinguir os diferentes objetos em uma cena. Esses objetos, denominados de *objetos audiovisuais* (textos e figuras), são entidades

semânticas que precisam ser definidas, manipuladas e, em seguida, codificadas segundo o esquema mais apropriado para as suas características. O padrão MPEG-4 define diversas funcionalidades que devem ser atribuídas a um sistema de codificação, onde a decomposição de uma cena em objetos audiovisuais é uma das características mais importantes.

Freqüentemente, as técnicas automáticas de segmentação devem se reportar ao tipo de aplicação, já que a definição e compreensão de semântica pode mudar de um domínio a outro. Outra forte característica dos sistemas de segmentação é a interação do usuário, seja para corrigir eventuais problemas no processo de segmentação, seja para identificar os objetos de interesse. A interação pode se dar em diversos níveis, que vão do uso de marcadores ou contornos na identificação e delineamento do objeto até a constante adequação dos parâmetros do sistema. Além disso, a interação com o usuário pode ser realizada antes, durante e depois da execução de um algoritmo de segmentação, o que permite correções e refinamentos do resultado desejado.

Nos últimos anos, o advento da segmentação com base no estudo de hierarquias, denominada de *segmentação multiescala*, possibilitou o surgimento de novas técnicas de decomposição de imagens, efetuadas de forma mais natural e semelhantes ao processo realizado pelo sistema visual humano. A segmentação multiescala veio a contribuir fortemente, por exemplo, para a codificação via padrão MPEG-4 [17],[20]. E ainda, a segmentação multiescala usada em processamento de imagens, cuja base é originária da teoria da classificação/taxonomia [57],[56], possibilitou a revisão e expansão de algoritmos já existentes com a inclusão da informação hierárquica na solução dos problemas. É o caso, por exemplo, das tarefas de segmentação e casamento de imagens abordadas nesta tese.

Representação e segmentação de imagens podem ser baseadas na Morfologia Matemática, que representa um ramo não linear das técnicas de processamento de imagens [26]. A Morfologia Matemática é uma teoria que permite o estudo das formas e a análise das estruturas espaciais, baseada na teoria dos conjuntos [22]. A Morfologia Matemática foi introduzida por dois pesquisadores franceses, G. Matheron e J. Serra, em meados da década de 60. A interessante história da Morfologia Matemática é descrita pelos próprios criadores em um recente artigo publicado no *International Symposium on Mathematical Morphology*[23].

1.2 Objetivos

Nesta tese, opta-se por trabalhar com a segmentação multiescala. Essa abordagem de segmentação permite obter uma hierarquia de partições presentes em uma imagem. A forma de representação de uma hierarquia aqui adotada é a *Árvore dos Lagos Críticos*, construída a partir do processo de inundação da Transformada de Watershed, a ferramenta clássica de segmentação em Morfologia Matemática. Em adição, as partições geradas na Árvore dos Lagos Críticos são aninhadas, ou seja, partições em um nível superior contêm as partições de nível mais baixo e representam as fusões entre regiões primitivas da imagem.

Através deste tipo de modelagem e utilizando-se de técnicas de teoria dos grafos, este trabalho explora duas importantes tarefas em processamento de imagens, que são o casamento de objetos e a segmentação de imagens com base no espaço de escalas, à luz de uma ótica hierárquica. Casamento hierárquico de imagens torna-se uma tarefa de correspondência entre grafos ou árvores, tal que a informação dos níveis dos seus nós (que correspondem às regiões e suas fusões) seja relevante neste processo. Segmentação de imagens através da análise do espaço de escalas se baseia no fato de que os objetos semanticamente importantes estão representados em diferentes escalas da imagem e, portanto, uma análise de todo o espaço ao invés de uma só escala pode apresentar melhores resultados.

Por fim, com o conjunto de ferramentas e programas gerados neste trabalho, pretende-se contribuir para o desenvolvimento de uma *toolbox* em processamento digital de imagens e visão computacional.

1.3 Organização da Tese

Esta tese é constituída de 6 capítulos, de forma a apresentar todas as áreas envolvidas na análise hierárquica de imagens. A seguir, é feito um breve resumo sobre cada um destes capítulos.

Capítulo 2 — Introduz o processo de segmentação de imagens através da Morfologia Matemática. Neste âmbito, discute-se a Transformada de Watershed, a ferramenta básica de segmentação, apresentando sua definição, propriedades e tipos de inundação. Além disso, explicam-se os conceitos associados à hierarquia de imagens a fim de se obter partições que representem

adequadamente o seu conteúdo semântico.

Capítulo 3 — Explica a construção da árvore dos lagos críticos e sua utilização na obtenção de partições, além de apresentar as linhas gerais de algumas das principais estruturas hierárquicas presentes na literatura. A árvore dos lagos críticos é construída com base na Transformada de Watershed. A intervenção humana pode atuar em partes específicas da árvore dos lagos críticos, permitindo obter partições que beneficiem características locais da imagem. Apresenta também uma metodologia para o cálculo dos pesos dos contornos das regiões de uma imagem a fim de se efetuar uma segmentação multiescala com base na análise do nível de cinza dos contornos.

Os capítulos seguintes realizam tarefas distintas e independentes. A linha que os une é a representação adotada neste trabalho, a árvore dos lagos críticos, e a busca por uma solução através da análise hierárquica do problema.

Capítulo 4 — O problema de casamento de imagens torna-se um problema de casamento de grafos na medida em que, como visto no capítulo anterior, as imagens são representadas por árvores. Neste capítulo, propõe-se um algoritmo de casamento de grafos que considera a informação hierárquica presente na estrutura das imagens. É realizada uma aplicação para uma sequência de imagens de Ressonância Magnética do ventrículo esquerdo do coração, cedida pelo Instituto do Coração de São Paulo.

Capítulo 5 — Este capítulo é dedicado à segmentação de imagens com base na análise do espaço de escalas. A análise é feita através da avaliação de atributos calculados para todos os nós (regiões) da árvore dos lagos críticos. Esses atributos podem ser classificados em hierárquicos (tempo de vida), níveis de cinza (média, variância), geométricos e morfológicos (área, perímetro, volume). O capítulo apresenta ainda uma aplicação na segmentação de imagens de células de leveduras, em colaboração com a Faculdade de Engenharia de Alimentos da UNICAMP.

Finalmente, no capítulo de conclusões discutem-se as contribuições e perspectivas deste trabalho à luz das técnicas implementadas. Desdobramentos dos trabalhos iniciados, assim como limitações das técnicas também são discutidas neste capítulo.

Capítulo 2

Segmentação de imagens

O objetivo deste capítulo é apresentar o processo de segmentação de imagens através da Morfologia Matemática. Neste âmbito, discute-se a Transformada de Watershed, a ferramenta básica de segmentação, apresentando sua definição, propriedades e tipos de inundação.

Finalmente, pretende-se explicar os conceitos associados à hierarquia de imagens a fim de se obter partições que representem adequadamente o seu conteúdo semântico.

2.1 Introdução

No domínio da Morfologia Matemática, segmentação de imagens é realizada primordialmente através da Transformada de Watershed, desenvolvida no final dos anos 70 [6] e que instiga pesquisas até os dias atuais. Watershed é uma técnica genérica de segmentação de imagens, semelhante às técnicas de crescimento de regiões, utilizada com sucesso nas mais diferentes classes de imagens.

O Watershed foi explicado exhaustivamente na literatura [6],[9],[10],[26]. Nas seções seguintes, apresenta-se o Watershed de forma sucinta, através de uma analogia já clássica entre um processo de inundação de um relevo topográfico (imagem) e a formação de bacias de captação (regiões) e diques de contenção de águas (contornos).

Devido ao processo de super-segmentação de regiões gerado pelo Watershed, a necessidade de pré ou pós-tratamento na análise de imagens tornou-se cada vez maior em sistemas de visão computacional que utilizam esta técnica. Dessa forma, o uso de conceitos provenientes da Taxonomia, especificamente

de estruturas hierárquicas, vêm sendo utilizados com maior frequência por pesquisadores da área. Aliado a essa deficiência do Watershed, a Taxonomia aporta diversas outras contribuições, como as que serão descritas no Capítulo 5. Na Seção 2.2, apresentam-se as definições ligadas à teoria da classificação no que diz respeito à hierarquia e obtenção de partições de imagens, que constituem a base para o chamado Watershed Hierárquico.

2.2 Watershed

2.2.1 Definições básicas

Antes de explicar o algoritmo de Watershed propriamente dito, é preciso definir alguns conceitos básicos da Morfologia Matemática utilizados ao longo deste Capítulo.

Definição 1 (Tipo de vizinhança) *Vizinhança (Viz) define uma relação entre pontos de uma imagem. As relações de vizinhança (ou adjacência) mais utilizadas são do tipo 4 ou 8, chamadas de vizinhança-4 e vizinhança-8. A Figura 2.1 ilustra este conceito.*




Figura 2.1: Tipos de vizinhança ao *pixel* p , em cinza: (a) vizinhança-4; (b) vizinhança-8.

Definição 2 (Componentes Conexos) *Seja P um conjunto de pixels que contém um pixel p . O componente conexo de P que contém p , denominado de $CC_p(P)$, é a união de todos os caminhos de origem em p e que estão contidos em P . Existe um caminho ligando dois pixels i e j se, e somente*

1	2	4	3	3
3	6	4	3	5
5	7	5	6	6
10	10	10	8	8
12	5	5	8	6

(a)

Figura 2.2: (a) Exemplos de zonas planas, em preto.

se, existe uma seqüência de pixels $(p_0, p_1, \dots, p_n)$ tal que $p_0 = i$, $p_n = j$ e $p_i \in Viz(p_{i-1})$, $\forall i = 1, \dots, n$.

Definição 3 (Zonas Planas) Zonas Planas são os componentes conexos da imagem que possuem mesma intensidade de nível de cinza. Na Figura 2.2 são apresentados, em preto, alguns exemplos de zonas planas numa imagem sintética.

Definição 4 (Mínimo Regional) Mínimos regionais são zonas planas que possuem vizinhos com zonas planas de maior intensidade em nível de cinza. Esse conceito é ilustrado na Figura 2.3.

1	2	4	3	3
3	6	4	3	5
5	7	5	6	6
10	10	10	8	8
12	5	5	8	6

(a)

Figura 2.3: (a) Mínimos Regionais de uma imagem.

Mínimo local é o pixel (ou zona plana) que não possui vizinhos de menor intensidade em nível de cinza. O mínimo global é aquele que possui menor intensidade de cinza dentre os mínimos regionais.

Definição 5 (Dinâmica) *O conceito de dinâmica foi introduzido por Grimaud em sua tese de doutorado[16]. A dinâmica de um mínimo regional m_1 é igual à $h - \text{altitude}(m_1)$, onde h é a menor altura que deve ser vencida para alcançar o mínimo m mais profundo que m_1 , como mostra a Figura 2.4.*




Figura 2.4: (a) Dinâmica de um mínimo.

Por definição, a dinâmica do mínimo global é infinito (ou igual à maior intensidade de cinza, no caso discreto). Na Figura 2.3, por exemplo, a dinâmica do mínimo de nível de cinza 5 é igual a 3 e para o mínimo de nível de cinza 1, a dinâmica vale 11.

2.2.2 Watershed baseado na simulação de imersão

Neste método clássico de segmentação morfológica, uma imagem f é tratada como um relevo topográfico, sendo a altitude representada pelos níveis de cinza. Geralmente utiliza-se a imagem do gradiente morfológico, pois esta imagem oferece um melhor posicionamento para os contornos das regiões, correspondentes às linhas de cresta ou transições entre as regiões da imagem. A Figura 2.5 ilustra a interpretação de uma imagem através de uma superfície topográfica.

A seguir, apresenta-se a definição do gradiente. Outros conceitos e uma apresentação geral da morfologia matemática podem ser vistos em [24],[25], [26].

Definição 6 (Gradiente morfológico) *O operador $\psi_{grad}(f)$ define o gra-*




Figura 2.5: Visualização de uma imagem: (a) imagem original *camera man*; (b) gradiente morfológico de (a); (c) visualização através de um relevo.

diente morfológico através da equação

$$\psi_{grad}(f) = f \oplus b - f \ominus b \quad (2.1)$$

onde b é um elemento estruturante que contém a origem e os operadores $\oplus$ e $\ominus$ representam a dilatação e a erosão morfológicas, respectivamente.

Para a explicação do Watershed, considere o seguinte problema hidrológico: suponha que o relevo seja inundado progressivamente a partir de fontes de água posicionadas nos mínimos regionais da imagem. A água proveniente das fontes provoca a formação de lagos ou bacias hidrográficas, chamadas de *bacias de retenção*. No momento em que duas bacias diferentes tentam se juntar, uma barragem ou linha de contenção é construída para impedir este processo. A Figura 2.6 ilustra a imersão de um relevo topográfico e a formação de bacias de retenção.

Ao final do processo de imersão, a coleção de todas as barragens representa as *linhas de watershed* e as bacias de retenção, as *regiões de watershed*. A representação da imersão através de águas coloridas é bastante ilustrativa para o entendimento do watershed, como visto na Figura 2.6. Neste caso, não é permitida a mistura de águas de cores diferentes, o que proporciona a formação das regiões do watershed.

No que diz respeito a algoritmos, basicamente existem duas maneiras diferentes de efetuar a inundação de um relevo topográfico: síncrona e uni-forme. A Figura 2.7 ilustra estes dois processos de inundação.




Figura 2.6: Princípio da imersão de uma imagem:(a) imagem original e seus mínimos; (b) criação de barragens; (c) imagem imersa.

- *Síncrona*

As fontes de água escoam em todos os mínimos simultaneamente neste processo de inundação. O nível da água em todas as bacias de retenção é constante até que atinja um ponto de transição entre bacias (menor altura máxima). Em seguida, os lagos provenientes de bacias diferentes continuam a crescer, separados por uma linha de watershed.

- *Uniforme*

O nível de água começa a crescer a uma velocidade constante a partir do mínimo de menor altitude. A medida que o nível aumenta, outros mínimos (e bacias) começam a ser inundados. Na seqüência, o processo é semelhante à inundação síncrona.

A segmentação via watershed como explicada anteriormente é denominada de *watershed clássico* ou *tradicional*. Uma característica desta metodologia é a super-segmentação da imagem, provocada pela presença da grande quantidade de mínimos regionais. Uma alternativa para este problema é a utilização de somente alguns mínimos regionais ou de um conjunto restrito de pontos na imagem, chamados de marcadores. A seleção e posicionamento dos marcadores passa a ser um problema de "inteligência" do sistema de segmentação. Alguns trabalhos relacionados a essa análise podem ser encontrados em [19],[21]. Essa versão da transformada de Watershed passa a ser chamada de *Watershed por marcadores*.

Algoritmos eficientes de implementação do watershed são dados em [9],[10].




Figura 2.7: Diferentes tipos de inundação: (a) e (b) síncrona; (c) e (d) uniforme. São ilustradas as configurações do início da inundação e do primeiro contato entre duas bacias formadas pelos mínimos m_1 e m_2 .

2.3 Segmentação Multiescala

A segmentação multiescala ou hierárquica tem por objetivo a obtenção de partições da imagem que sejam naturalmente mais simples, adequadas ao propósito do problema, e que representem o conteúdo semântico da imagem. Essa não é uma tarefa fácil de ser realizada de forma automática e pode, portanto, envolver a intervenção humana. Veja, em primeiro lugar, as definições de partição e hierarquia.

Definição 7 (Partição) *Uma partição P de uma imagem f é um conjunto de regiões disjuntas R_i , $i = 1, 2, \dots, n$, onde a união das regiões forma a imagem completa.*

$$P = \{R_1, R_2, \dots, R_n\} \quad (2.2)$$

onde $\bigcup R_i = f$, $R_i \cap R_j = \emptyset$, $i \neq j$.

Definição 8 (Hierarquia) *Seja P_k um conjunto de partições $P_1, P_2, \dots, P_n$, de uma imagem f . P_k é uma hierarquia, também chamada de seqüência de*

partições aninhadas, se para $i < j$, $P_i \supset P_j$. Significa dizer que uma partição em um dado nível é obtida misturando-se regiões de uma partição em um nível imediatamente inferior. Outras definições de hierarquia são encontradas em [56],[57].

A Figura 2.8 apresenta um exemplo de hierarquia a partir de uma imagem artificial com somente 5 regiões. Nesta Figura, as partições vão se sucedendo do nível mais fino ao mais grosseiro. A análise do processo de fusão de regiões em uma imagem e a obtenção de partições são objetos de estudo do próximo capítulo. Exemplo de partições para uma imagem real é dado na Figura 2.9. São calculadas diversas partições com base nas regiões e nos contornos das regiões da imagem. O problema da segmentação multiescala obtida com base nos contornos das regiões de uma imagem também será explorado no capítulo seguinte.




Figura 2.8: Construção de uma hierarquia para uma imagem artificial.

Com base nas definições acima, trabalhos recentes [19], [5] definem um novo tipo de watershed, denominado de *watershed hierárquico*. Nesta metodologia, a inudação é iniciada a partir de um limiar t que representa alguma característica topográfica do relevo, tal como altura, dinâmica, volume ou área. Quanto maior o valor de t , menor a quantidade de regiões da partição obtida. Duas métricas bastantes utilizadas na literatura devido aos bons resultados apresentados são a dinâmica e o volume. Na imagem da Figura 2.9, a métrica utilizada foi o volume. Obtém-se partições associadas às regiões e aos contornos da imagem *camera man*.

As técnicas de segmentação hierárquicas vêm sendo bastante utilizadas devido à sua simplicidade e variedade de metodologias de representação. Normalmente, na segmentação hierárquica são produzidos bons resultados devido à sua semelhança com o sistema visual humano, cuja percepção e visualização de objetos se dá através de uma representação hierárquica.




Figura 2.9: Exemplo de partições para a imagem *camera man*. Partições associadas às regiões da imagem: (a) partição com 5 regiões; (b) partição com 10 regiões; (c) partição com 20 regiões. Partições associadas aos contornos das regiões da imagem: (d) partição com 25 regiões; (e) partição com 15 regiões; (f) partição com 2 regiões.

Em análise de movimento em imagens, técnicas hierárquicas são muito utilizadas por ser mais fácil e eficiente estimar o movimento de objetos a baixa resolução e depois refinar as estimativas com informação proveniente de resoluções cada vez mais altas. Uma outra boa razão para o uso de representações hierárquicas é a possibilidade de realizar segmentação de imagens baseada na análise de todo o espaço de escalas, como será visto no Capítulo 5.

Capítulo 3

Representação Hierárquica de imagens

No capítulo anterior foram apresentados os conceitos relacionados à hierarquia de partições e segmentação morfológica. Este capítulo é dedicado à modelagem de imagens através de estruturas de grafos, a fim de se obter representações hierárquicas de imagens.

Tem-se como objetivo apresentar as linhas gerais de algumas das principais estruturas hierárquicas e, de maneira mais aprofundada, explicar a construção da árvore dos lagos críticos e sua utilização na obtenção de partições. A árvore dos lagos críticos é construída com base na Transformada de Watershed. Mostra-se que a intervenção humana pode atuar em partes específicas da árvore dos lagos críticos, permitindo obter partições que beneficiem características locais da imagem.

3.1 Introdução

Uma poderosa estrutura de dados utilizada na representação de objetos em problemas de reconhecimento de padrões e visão computacional são os grafos. Normalmente, objetos são modelados pelos nós do grafo, e as relações entre objetos são representadas pelas arestas. Além da simplicidade na modelagem, os grafos possuem várias propriedades matemáticas interessantes para a resolução dos problemas.

Por outro lado, a informação hierárquica observada em sistemas de visão humana freqüentemente auxilia e facilita a determinação de uma solução eficiente. As estruturas hierárquicas têm uma grande capacidade de modelar

sistemas complexos e permitem representar simultaneamente características quantitativas e propriedades semânticas [46].

Portanto, este trabalho utiliza árvores na modelagem de imagens, uma estrutura útil na interpretação das mesmas, permitindo representar suas informações topológicas e morfológicas. Em adição, as árvores são hierárquicas, pois apresentam uma relação de ordem entre seus nós. Exemplos de estruturas com essas características, utilizadas em problemas de casamento e segmentação de imagens, são a árvore dos componentes [63],[47],[44], a árvore de partição binária [50],[49] e a árvore dos lagos críticos [60],[28],[62].

Este capítulo começa apresentando algumas noções sobre grafos e árvores, na Seção 3.2. Em seguida, na Seção 3.3, descrevem-se os princípios básicos da árvore dos componentes e da árvore de partição binária, duas estruturas bastante utilizadas na representação de imagens, de características semelhantes à ALC. Depois, na Seção 3.4 apresentam-se a definição, algoritmos e formas de utilização e interação com a árvore dos lagos críticos. Duas contribuições são descritas neste capítulo: a primeira (ainda na Seção 3.4), uma aplicação das operações hierárquicas locais na segmentação de uma seqüência de imagens de ressonância magnética do ventrículo esquerdo do coração; e a segunda (Seção 3.5), um algoritmo para quantificar os contornos das regiões de uma imagem a partir da árvore dos lagos críticos e da árvore geradora mínima.

3.2 Grafos - Notações e definições

Os parágrafos seguintes limitam-se a apresentar as definições sobre grafos e árvores utilizadas em nosso trabalho. O leitor interessado em um estudo completo da teoria dos grafos poderá consultar [81],[82].

Um grafo G normalmente é definido por $G = (V, E)$, sendo que V representa o conjunto de nós e E , o conjunto de arestas (i, j) , onde $i, j \in V$. Um subgrafo $G_1 = (V_1, E_1)$ de G é um grafo tal que $V_1 \subset V$ e $E_1 \subset E$. Dois nós i, j são vizinhos, denotado por $i \sim j$, se eles estão conectados por uma aresta. Um caminho entre i_1 e i_n é a lista $(i_1, i_2, \dots, i_{n-1}, i_n)$, onde $i_k \sim i_{k+1}$, $k = 1, 2, \dots, n - 1$. Dois nós i, j são conectados se existe ao menos um caminho entre i e j . Um grafo G é dito conexo se existe um caminho para qualquer par de nós (i, j) pertencente à G . Um caminho onde $i_1 = i_n$ é chamado de ciclo. Um grafo conexo sem ciclos é chamado de árvore.

Quando se designa um nó em particular de uma árvore para servir como raiz, se deseja especificar uma relação de hierarquia entre os nós. Esta árvore

é chamada de *árvore hierárquica* [81]. O comprimento do caminho entre o nó i e a raiz é denominada de nível. A raiz tem nível 0 e os nós imediatamente abaixo da raiz têm nível 1, por exemplo. A relação de um nó i que está em um nível imediatamente inferior a um nó j é chamada de relação pai-filho (i é filho de j). Para nós em diferentes níveis as relações entre pais e filhos tornam-se relações entre ancestrais e descendentes. Uma árvore hierárquica onde cada nó dá origem a dois outros nós de nível inferior é chamada de árvore binária.

Em um grafo ponderado, é associado um peso (ou um conjunto de pesos) à aresta que vai do nó i ao nó j , representado por $w(i, j)$. Quando pesos são associados aos nós de um grafo ao invés das arestas, esse grafo é denominado de *grafo com atributos*, definido por $G = (V, E, A)$, onde A representa o conjunto de atributos dos nós do grafo. A distância entre dois nós i e j , $d(i, j)$, é definida como o comprimento do menor caminho entre os comprimentos de todos os caminhos existentes entre i e j . Denomina-se excentricidade de um nó $i \in V$ ao valor da distância máxima entre i e j , para todo $j \in V$. O centro de G é então o subconjunto de nós de excentricidade mínima.

Uma árvore T , subgrafo de G , que contenha todos os nós de G é denominada de *árvore geradora*. Um grafo pode ter diversas árvores geradoras. A árvore geradora cuja soma dos pesos de suas arestas seja menor do que a soma dos pesos de qualquer outra árvore geradora do mesmo grafo é chamada de *árvore geradora mínima*.

3.3 Outras estruturas de árvore na representação de imagens

Dentre diversas estruturas hierárquicas utilizadas na literatura para representar imagens, esta seção apresenta duas importantes árvores dedicadas, principalmente, à resolução de problemas de segmentação de imagens: árvore dos componentes e árvore de partição binária.

- *Árvore dos Componentes*. A árvore dos componentes é a representação de uma imagem em nível de cinza que contém informação sobre cada componente conexo presente na imagem. As relações existentes entre os componentes conexos são obtidas por decomposição via limiarização da imagem. A Árvore dos Componentes tem sido utilizada frequentemente para realizar segmentação de imagens [44],[47], além de ser uma




Figura 3.1: Construção de uma árvore dos componentes: (a) imagem original; (b) I_1 ; (c) I_2 ; (d) I_3 ; (e) I_6 ; (f) árvore completa.

representação de base para outras operações, como por exemplo, casamento de imagens [63]. A idéia da obtenção de tal árvore é originária do artigo de Hanusse e Guillataud [46], que trata de uma representação hierárquica de imagens gerada a partir do processo de inundação. A Figura 3.1 mostra um exemplo de construção da árvore dos componentes para uma imagem 5×5 . Seja Z o conjunto dos números inteiros e $k \in Z$. As imagens I_k ilustradas nas Figuras 3.1(b)-(e) são obtidas através da equação:

$$I_k = \{i \in I \mid I(i) \geq k\} \quad (3.1)$$

onde i corresponde aos níveis de cinza da imagem I ; I_k é chamada de *sessão transversal* de I .

Para cada componente conexo na imagem existe um nó correspondente na árvore. Um arco liga dois nós se o componente conexo em um dado nível de cinza está contido no componente de nível imediatamente inferior. A raiz da árvore é representada pelo nível de cinza de menor valor.

Na literatura, uma outra denominação para esta estrutura é de *árvore de confinamento* [63],[48] ou *Max-Tree* [50]. Um trabalho que fornece

algoritmos eficientes para a implementação da árvore dos componentes é apresentado em Mattes [48].

- *Árvore de Partição Binária.* A Árvore de Partição Binária (APB) foi originalmente proposta para processar e filtrar imagens [49]. A APB é uma representação estruturada e compacta de regiões de uma imagem e que fornece a relação entre regiões em diferentes escalas [50]. As regiões são obtidas através de algum método de crescimento de regiões ou watershed e constituem a partição fina da imagem que será submetida a um algoritmo de agrupamento de regiões. Sobre essa partição fina, obtém-se um grafo de adjacência que descreve as relações de vizinhança entre regiões. Para especificar completamente o algoritmo de agrupamento de regiões, é preciso definir três fatores: a ordem de agrupamento, o critério de agrupamento e o modelo de região criada pelo agrupamento [50]. A ordem de agrupamento define a ordem em que as regiões são processadas, normalmente definida por algum critério de similaridade; o critério de agrupamento define a continuidade do algoritmo de agrupamento, após a realização de cada junção de regiões; e o modelo de região determina como será representada a nova região formada pela união de outras duas.

A Figura 3.2 apresenta um exemplo de construção de APB a partir de uma partição inicial com 4 regiões mostrada na Figura 3.2(a). A título de simplificação o agrupamento é efetuado segundo um critério de homogeneidade de nível de cinza, mas outros podem ser utilizados, como por exemplo, a informação de movimento de objetos em uma seqüência de imagens. Neste exemplo, a seqüência do agrupamento é (1, 3), (2, 4) e (5, 6), onde as regiões 5 e 6 são os rótulos das regiões formadas pela união de (1, 3) e (2, 4), respectivamente.

À primeira vista, pode-se dizer que a árvore de partição binária é uma generalização das representações por árvores citadas até o momento, incluindo a árvore dos lagos críticos. As diferenças ficam no campo do algoritmo de segmentação e da ordem do agrupamento. Vários trabalhos usam essa representação, sobretudo para criar esquemas de descrição de seqüência de imagens para o sistema MPEG-7 [51]-[53].

Uma idéia semelhante à APB já havia sido desenvolvida no trabalho de Wu e Leahy [55], que trata de um algoritmo de agrupamento de regiões a partir do grafo de vizinhança de uma imagem.




Figura 3.2: Construção de uma árvore de partição binária.

3.4 Árvore dos lagos críticos

A Árvore dos Lagos Críticos (ALC) é uma das melhores estruturas para se visualizar o processo de fusão das bacias de retenção e, portanto, a hierarquia de fusão de regiões em uma imagem. Primeiramente, iremos definir um lago crítico.

Definição 9 (Lago Crítico) *É o lago criado no momento da fusão entre duas bacias de retenção de água no processo de inundação do relevo topográfico. Na Figura 3.3, a fusão das bacias A e B produz o lago crítico C. Um lago crítico também pode ser formado pela fusão de outros lagos críticos ou pela junção entre um lago crítico e uma bacia de retenção.*




Figura 3.3: Formação de um lago crítico em um relevo topográfico.

A transformação de uma imagem para árvore dos lagos críticos pode ser visualizada a partir da Figura 3.4. Neste processo, os mínimos regionais da imagem (3.4(a)) são associados aos nós na ALC. Estes mínimos serão as folhas da árvore. Durante o processo de inundação, a cada fusão entre dois lagos é criado um novo nó na árvore, de nível superior e rótulo diferente, como mostrado nas Figuras 3.4(b)-(d). Além disso, também é avaliada a aresta que conecta os nós, através do cálculo da ultramétrica associada, como será visto na próxima seção. Portanto, os eventos importantes só acontecem no momento de fusão entre os lagos. O processo é concluído quando toda a imagem está inundada e a árvore atinge a sua raiz (3.4(d)).




Figura 3.4: Construção da árvore dos lagos críticos.

O exemplo de formação da ALC apresentado pela Figura 3.4 foi construído a partir de uma inundação do tipo uniforme. Como os eventos importantes para a ALC só acontecem na fusão entre dois lagos (criação de um novo lago e cálculo da ultramétrica associada), a árvore obtida utilizando-se a inundação síncrona seria a mesma. A diferença ficaria por conta dos valores das ultramétricas calculadas.

O conceito de lago crítico permite redefinir a dinâmica de um mínimo m como sendo a *profundidade do lago máximo* associado a m , onde um lago

máximo é aquele existente na iminência da fusão com um lago de maior profundidade[1].

3.4.1 Construção da ALC via Árvore Geradora Mínima

Infelizmente a construção da ALC como ilustrada na Figura 3.4 é válida quando se leva em consideração somente a altitude na qual as fusões acontecem. Neste caso, a topologia da árvore e o cálculo dos pesos das arestas são ascendentes de acordo com o andamento da inundação. No entanto, quando se utiliza outras ultramétricas, a árvore dos lagos críticos só pode ser obtida através da Árvore Geradora Mínima – AGM [3]. Uma ultramétrica é uma métrica que satisfaz as condições de uma distância:

$$d(x, y) = 0, \quad \text{se } x = y \quad (3.2)$$

$$d(x, y) = d(y, x) \quad (3.3)$$

$$d(x, z) \leq d(x, y) + d(y, z) \quad (3.4)$$

onde x , y e z são lagos na superfície topográfica. Além das condições acima, também se observa [56]:

$$d(x, z) \leq \max(d(x, y), d(y, z)) \quad (3.5)$$

As ultramétricas usadas para validar as arestas são também conhecidas como *valor de extinção das bacias de captação* [18]. Os valores de extinção normalmente usados na literatura são a altura, área, volume e dinâmica, sendo este dois últimos os que apresentam melhores resultados [17]. Os valores de extinção são medidos no momento da fusão entre dois lagos: dentre os valores calculados para cada lago da métrica adotada, escolhe-se sempre o de menor valor absoluto.

Um exemplo de construção de AGM a partir de uma imagem é dado na Figura 3.5. O valor de extinção escolhido foi o volume e a vizinhança é do tipo vizinhança-4.

O cálculo do valor de extinção é realizado da seguinte forma. Por exemplo, a Figura 3.5(c) mostra o momento da fusão entre os lagos 1 e 3, cujos volumes são $vol_1 = 6$ e $vol_3 = 3$. Portanto, o lago de menor volume desaparece e o lago crítico 5 é formado. O valor do peso associado à aresta entre os lagos 1 e 3 é igual a 3, o menor dos volumes. O processo se repete até a completa




Figura 3.5: Exemplo de construção da árvore geradora mínima durante o processo de inundação: (a) imagem original; (b) imagem dos mínimos rotulados; (c)-(e) encontro entre bacias; (f) imagem inundada.

inundação da imagem, Figura 3.5(f), tomando-se somente os primeiros pontos onde as bacias se tocam. A AGM formada é mostrada na Figura 3.6.

Existem diversos algoritmos morfológicos de obtenção de AGM a partir do processo de inundação de imagens. O leitor poderá encontrar alguns em Meyer [3] e Silva [19].

Meyer [3] propôs uma metodologia de transformação de Árvore Geradora Mínima (AGM) para ALC. Tendo-se o custo de fusão entre as regiões da imagem, duas a duas, o procedimento para cálculo da ALC consiste em reunir sucessivamente duas regiões x e y que possuem o menor custo, ou seja determina-se (x, y) que minimiza $C(x, y)$. Em seguida, é calculado o custo entre a nova região z (criada pela fusão) e os vizinhos das regiões originais x e y . O Algoritmo 1 explica esse processo. A Figura 3.7 ilustra passo a passo a conversão de uma AGM para ALC.

Na definição de Meyer, a ALC possui arcos orientados. Basicamente, o objetivo é identificar quais regiões se fundiram para dar origem a outra, além de fornecer a ordem de fusão.




Figura 3.6: Árvore geradora mínima da Figura 3.5(a).

Algoritmo 1 Transformação de Árvore Geradora Mínima em Árvore dos Lagos Críticos.

Para todos os arcos da AGM **Faça**

Determinar $(x_1, y_1) / C(x_1, y_1) = \min(C(x, y))$

Suprimir (x_1, y_1)

Criar um novo nó z . Criar arcos orientados (x_1, z) e (y_1, z)

Trocar: os vizinhos de x_1 e y_1 passam a ser vizinhos de z

Fim Para

Uma observação atenta deste processo, leva a realizar uma comparação entre a conversão AGM para ALC e o algoritmo de agrupamento do tipo Ligação Simples [56]. Este tipo de agrupamento pertence ao grupo de construção ascendente de hierarquias e seu princípio geral é bastante simples e análogo ao processo de transformação AGM - ALC. As regiões são agrupadas duas a duas, sucessivamente, de modo a fundir as regiões mais próximas (menor distância). A cada fusão, recalculam-se as distâncias entre a região criada e as outras regiões da imagem, através da equação:

$$d(x \cup y, z) = \min(d(x, z), d(y, z)) \quad (3.6)$$

onde x , y e z são regiões da imagem e $x \cup y$ é uma nova região criada a partir da fusão entre x e y .

As classificações via Ligação Simples têm uma tendência de comprimir ou aproximar os níveis de agrupamento, provocando o chamado *efeito cadeia* [56].




Figura 3.7: Exemplo de transformação de AGM para ALC via Algoritmo 1: (a) AGM da Figura 3.6; (b)-(d) etapas da transformação e árvore final em (d).

3.4.2 Representação da ALC

Uma das melhores maneiras de representar a hierarquia de fusões de regiões é através de gráficos e árvores. O *dendrograma indexado* é uma ferramenta bastante utilizada na taxonomia.

Definição 10 (Dendrograma Indexado) *Um Dendrograma indexado é uma representação gráfica de uma seqüência aninhada de partições, onde os índices correspondem aos níveis em que as partições foram formadas [58].*

Em Morfologia, os índices hierárquicos correspondem às distâncias ultramétricas utilizadas na inundação do relevo.

A Figura 3.8 apresenta o dendrograma da árvore dos lagos críticos da Figura 3.7. No eixo horizontal encontram-se os nós que representam as folhas da ALC (bacias do watershed). O eixo vertical indica as distâncias ultramétricas.

A representação matricial do dendrograma da Figura 3.8 é indicada pela Tabela 3.1. Essa é a mesma notação utilizada pelo software *MATLAB*.




Figura 3.8: Dendrograma para a Figura 3.7.

2	4	2
1	3	3
5	6	8

Tabela 3.1: Representação matricial do dendrograma da Figura 3.8.

3.4.3 Construção de partições

A determinação de partições de uma imagem através de um dendrograma é bastante simples de ser visualizada. Considere o dendrograma da Figura 3.9. A limiarização a partir de T_1 produz uma nova imagem contendo 3 regiões. Já utilizando o limiar T_2 , a imagem possuiria 2 regiões. Neste caso, a operação de limiarização em dendrogramas é equivalente à supressão de arcos na árvore geradora mínima.

A Figura 3.10 apresenta alguns exemplos de partições aninhadas em imagens reais utilizando-se a métrica volume como valor de extinção e a representação de imagens via dendrogramas.

3.4.4 Operações hierárquicas locais

A interação humana nos algoritmos de segmentação de imagens é comumente aceita pelos pesquisadores, já que a variedade de aplicações e de tipos de imagens a serem tratadas é tamanha que torna-se praticamente impossível desenvolver algoritmos adaptados a todos os contextos [17][7]. Porém, a qualidade e a forma do processo de interação devem ser tais que exijam cada vez menos habilidades específicas do usuário (manuais ou técnicas inteligentes).




Figura 3.9: Construção de partições a partir da ALC. O limiar T_2 produz uma partição com duas regiões (quadrados pontilhados)

Por outro lado, as partições obtidas através do procedimento explicado na seção anterior nem sempre são adequadas ao tipo de problema com o qual se está trabalhando. A principal dificuldade está na atuação global dos algoritmos sobre as imagens, enquanto que, frequentemente, deseja-se trabalhar com objetos semânticos específicos. Por exemplo, numa imagem de uma casa poderíamos querer que o fundo fosse representado por somente uma região e que a casa apareça com suas portas, janelas e outros detalhes. Portanto, tentaríamos obter uma partição da imagem que contivesse essas características, o que nem sempre é possível.

As operações locais sobre a hierarquia construída para uma imagem permitem que se atue em partes específicas do dendrograma, como ilustrado pela Figura 3.11. A idéia é agir de maneira que se possa aumentar ou diminuir o nível de resolução sem alterar outras áreas da imagem. Além dessas operações, a representação hierárquica possibilita também uma forma diferente de selecionar regiões de interesse na imagem. A seguir, descrevem-se algumas das principais operações hierárquicas locais:

- **Re-segmentação** — Nesta operação, estamos interessados em dividir uma classe C em n diferentes regiões. Qualquer nó de um dendrograma que não seja uma folha é considerado uma classe. A interação acontece da seguinte forma: o usuário indica na imagem a classe que deseja refinar através de um clique com o mouse, além do número n de regiões em que a classe deve ser subdividida. A re-segmentação é feita sobre uma partição inicialmente calculada para a imagem. Após a indicação do




Figura 3.10: Exemplo de partições aninhadas em diferentes imagens: (a)-(c) imagem *escritório*; (d)-(f) imagem *mother*; (g)-(i) imagem *célula*.




Figura 3.11: Operações hierárquicas locais: seleção de uma região do dendrograma.




Figura 3.12: Operações hierárquicas locais – re-segmentação de uma partição: (a)-(c) re-segmentação da imagem *camera man* a partir de uma partição com duas regiões e partição com 20 regiões obtidas pelo processo sem re-segmentação; (d)-(f) resegmentação da face do menino na imagem *mother* a partir de uma partição com 7 regiões e partição com 22 regiões obtidas pelo processo sem re-segmentação.

usuário, o algoritmo identifica a parte do dendrograma correspondente àquela classe clicada pelo mouse e calcula a nova partição. A Figura 3.12 apresenta um exemplo dessa operação. As Figuras 3.12(a) e (d) são as partições que servirão de base para a re-segmentação geradas das imagens *camera man* (2 regiões) e *mother* (7 regiões); nas Figuras 3.12(b) e (e), apresentam-se partições com 20 e 22 regiões, atuando somente sobre o corpo do *camera man* e o rosto da criança na imagem *mother*, respectivamente; e nas Figuras 3.12(c) e (f), têm-se as partições com regiões geradas sem o processo de re-segmentação.

- **Supressão** — O objetivo da operação supressão é o de realizar a fusão de uma classe C especificada pelo usuário com o seu vizinho mais próximo. Primeiro, consideram-se os índices do dendrograma correspondentes às distâncias ultramétricas entre C e cada vizinho. Depois, é feita a fusão de C com seu vizinho C_x que minimiza essa




Figura 3.13: Operações hierárquicas locais – fusão de regiões da imagem: (a)-(c) exemplo da fusão do fundo na imagem *cameran man*; (d)-(f) exemplo da fusão das camisas na imagem *mother* (*frame 0*).

distância. A Figura 3.13 mostra um exemplo da operação de supressão, realizada para simplificar o fundo de uma imagem.

- **Seleção de ROI através de índice hierárquico** — Este é um método de seleção de Regiões de Interesse (*ROI* — *region of interest*) que não exige nenhuma habilidade manual do usuário. Normalmente, em trabalhos de perseguição e segmentação temporal é realizada uma segmentação inicial do objeto através da ajuda de marcadores e contornos. Alguns desses métodos exigem habilidades manuais do usuário no desenho dos contornos [7] ou na determinação dos marcadores [21].

A seleção de ROI através de índice hierárquico corresponde ao cálculo da excentricidade de um grafo (veja Seção 3.2), onde são informados o centro de um grafo (ou subgrafo) e uma distância máxima que corresponde a um raio R . Todos os nós pertencentes ao círculo de raio R farão parte da região de interesse.

Na prática, o usuário indica na imagem apenas um ponto no objeto de interesse, através do mouse, e um valor de índice hierárquico, que fun-

ciona como uma espécie de limiar. O algoritmo calcula a Transformada de Watershed e identifica o rótulo da região cujo pixel foi selecionado. Em seguida, todas as regiões cuja distância ultramétrica é menor do que o valor especificado são fundidas para formar a ROI. Exemplos de seleção de ROI para diversos tipos de imagens são mostrados na Figura 3.14.

As operações hierárquicas locais abrem possibilidades para diferentes tipos de aplicações, que vão desde a própria segmentação [5],[8] até a codificação e segmentação de seqüências de vídeo[17]. A sessão seguinte apresenta uma aplicação desenvolvida nesta tese com base nas técnicas descritas acima.

3.4.5 Segmentação temporal do ventrículo esquerdo do coração com base em operações hierárquicas locais

Uma aplicação que utiliza as operações hierárquicas locais na segmentação temporal do ventrículo esquerdo do coração é dada em [60],[61]. Em Carvalho [61] é feita uma comparação com uma segmentação manual realizada por especialistas. Os dados mostram diferença de cerca de 10% (para mais) entre a área segmentada manualmente e os resultados obtidos pela análise hierárquica. A seqüência de imagens do ventrículo esquerdo foi cedida pela Divisão de Informática do InCor — Instituto do Coração de São Paulo.

O algoritmo inicia-se pela escolha da região de interesse (ROI) no primeiro *frame* f_0 da seqüência de imagens. A ROI pode ser definida automaticamente ou através de interação com o usuário. Na prática, qualquer *frame* da seqüência pode ser usado como ponto de partida. A segmentação ocorre em *frames* subsequentes baseada em cálculos de medidas de similaridade e no uso de operações de adição e supressão de classes em dendrogramas indexados [61]. Estas operações incluem ou removem classes de forma hierárquica.

Então, o objetivo do processo de segmentação é obter uma seqüência de *ROIs* que serão denotadas por $(ROI_t)_{t \in [0, \dots, T-1]}$, onde T é o número de *frames*. A busca de cada ROI_t em cada *frame* $(f_t)_{t \in [0, \dots, T-1]}$ é realizada através dos seguintes passos:

1. (*Criação da ROI*) — A primeira *ROI* pode ser uma classe de uma partição (ou não). Seja $t = 0$. Para a ROI_0 , calcule o centróide e nível médio de cinza.




Figura 3.14: Operações hierárquicas locais – seleção de região de interesse via índices hierárquicos: (a) imagem *ventr005* de um ventrículo esquerdo e (b) ROI selecionada (índice = 900); (c)-(e) exemplo para a imagem *alice*; (f)-(h) exemplo para a imagem *bush*.

2. (*Representação multiescala*) — Calcule o dendrograma do *frame* f_{t+1} . Após isto, calcule a partição P_k para f_{t+1} . O nível k constitui um parâmetro do algoritmo e uma boa escolha normalmente depende do conhecimento da estrutura da imagem.
3. (*Detecção da classe*) — Encontre a classe C em P_k que contém o centróide de ROI_t .
4. (*Critério da distância entre centróides*) — Calcule a distância euclidiana d_{cent} entre os centróides de C e ROI_t . Se d_{cent} não estiver dentro de uma tolerância, aplique a operação de re-segmentação para C .
5. (*Teste de nível de cinza*) — Calcule a similaridade entre níveis de cinza médio entre a classe C e ROI_t . Se esta medida estiver fora de uma tolerância, aplicam-se operações de re-segmentação ou supressão.
6. (*Atualização da ROI*) — Armazene a classe atualizada C em ROI_{t+1} . Faça $t = t + 1$ e volte ao passo 2.

As Figuras 3.15 e 3.16 mostram os resultados para os *frames* *ventr028* e *ventr054*, respectivamente. Nestas figuras, ilustram-se os passos 4 e 5 da metodologia citada. As Figuras 3.15(b) e 3.16(b) mostram a imagem resultante após a aplicação do teste do centróide para a imagem original dada nas Fig. 3.15(a) e 3.16(a), respectivamente. A Figura 3.15(c) mostra a *ROI* detectada após a aplicação do teste de nível de cinza na imagem (operação de re-segmentação) representada pela Figura 3.15(b). A Figura 3.16(c) mostra a *ROI* obtida após a aplicação do teste de nível de cinza na imagem (operação de supressão) representado na Figura 3.16(b). As Figuras 3.15(d) e 3.16(d) mostram as *ROIs* obtidas sobrepostas nas imagens originais.

A Figura 3.17 apresenta o resultado da aplicação desta metodologia para uma fase completa da seqüência de imagens, consistindo dos *frames* *ventr019* a *ventr027*.




Figura 3.15: (a) *Frame* original *ventr028*; (b) classe selecionada após o teste do centróide (passo 4); (c) classe selecionada após teste do nível de cinza (passo 5); (d) *ROI* e imagem original sobrepostas.




Figura 3.16: (a) *Frame* original *ventr054*; (b) classe selecionada após o teste do centróide (passo 4); (c) classe selecionada após o teste do nível de cinza (passo 5); (d) *ROI* e imagem original sobrepostas.

3.5 Segmentação multiescala através da avaliação dos contornos de uma imagem

3.5.1 Introdução

A análise de imagens por visualização dos contornos de suas regiões é uma tarefa importante em segmentação de imagens. O problema consiste em gerar uma imagem em níveis de cinza dos contornos das regiões presentes na imagem, de tal forma que seja possível a obtenção de partições através da técnica de limiarização (binarização). Um diagrama de blocos deste problema é apresentado na Figura 3.18.

O posicionamento dos contornos das regiões é dado pelas linhas da Transformada de Watershed e os valores dos contornos são obtidos através do




Figura 3.17: (a) *Frames* originais *ventr019* a *ventr027*; (b) volume de sangue selecionado após análise hierárquica.




Figura 3.18: Diagrama esquemático do problema de segmentação através da avaliação dos contornos das regiões de uma imagem.

cálculo de algum atributo da região (dinâmica ou volume, por exemplo). Esses valores são atribuídos aos contornos obedecendo o critério de hierarquia (ver Seção 2.3). A operação de limiarização permite reduzir a super-segmentação que normalmente ocorre quando a Transformada de Watershed é aplicada a imagens de gradiente[14], suprimindo alguns mínimos da imagem e preservando a posição dos contornos.

A noção de hierarquia em morfologia matemática foi desenvolvida em diversos trabalhos [12],[5], mas a quantificação dos contornos deveu-se, principalmente, ao trabalho de Najman e Smith [13], através da análise de uma estrutura de árvore conhecida como Lista de Inundação. No trabalho de Najman e Smith [13], a Lista de Inundação é uma árvore cuja raiz é o mínimo de maior dinâmica, construída durante o processo de inundação efetuado pela Transformada de Watershed sem custo computacional adicional significativo[15].

Um exemplo de quantificação dos contornos de uma imagem e da aplicação do esquema descrito acima é dado na Figura 3.19. A Figura 3.19(a)

mostra a imagem original *alice*; nas Figuras 3.19(b) e (c) estão, respectivamente, a imagem em níveis de cinza (já quantizados) de todos os contornos das regiões de (a) e uma partição de (b) obtida via limiarização.




Figura 3.19: Exemplo ilustrativo do problema de segmentação através da avaliação dos contornos das regiões de uma imagem: (a) imagem original; (b) imagem dos contornos das regiões, em níveis de cinza; (c) partição de (b) obtida via limiarização (valores de contorno maiores que 1000).

Na sequência, apresenta-se o algoritmo clássico da lista de inundação e duas novas propostas de solução para o problema da quantificação dos contornos através da árvore dos lagos críticos e da árvore geradora mínima. Os algoritmos são ilustrados para imagens sintéticas. Resultados e uma breve discussão das três metodologias são apresentados na Seção 3.5.5.

3.5.2 Lista de inundação

Uma primeira metodologia para efetuar o cálculo dos pesos dos arcos no processo de inundação foi feito por Najman e Smith [13], sendo dados alguns esclarecimentos em Lemarechal[14] e Schmitt[15]. A idéia geral é construir uma lista, ou uma árvore, que possua todos os valores de extinção que serão associados às bordas, além de uma informação hierárquica indicando a relação entre as bacias do relevo topográfico. O Algoritmo 2 apresenta em linhas gerais a construção da lista de inundação.

A lista de inundação é atualizada no momento da fusão entre dois lagos (nós) m_1 e m_2 , cujos valores de extinção são $VE(m_1)$ e $VE(m_2)$, do seguinte modo:

- Pegam-se todos os pais (ancestrais) de m_1 e m_2 .

Algoritmo 2 Construção da Lista de Inundação

Início

Rotular os mínimos regionais m_r

Criar uma fila hierárquica FH (coordenadas e nível de cinza de m_r)

Criar a lista de inundação L

Inundação

Pegar o pixel p em FH de menor nível de cinza

Calcular o valor de extinção VE da bacia que contém p

Propagar o rótulo de p para seus vizinhos, segundo o critério de vizinhança escolhido

Guardar VE , quando duas bacias se tocam uma primeira vez

Se duas bacias b_1 e b_2 se tocam pela primeira vez **Então**

Determinar o pai e o filho, na lista de ancestrais de b_1 e b_2 , e colocar em L

Se Não

Procurar em L , o ancestral comum de b_1 e b_2 que tem o menor peso e associá-lo ao contorno

Fim Se

- Se $VE(m_1)$ é menor que $VE(m_2)$, m_2 é *pai* de m_1 . Então, pega-se na lista de pais de m_1 , o primeiro pai P_1 que possui o valor de extinção igual ou superior a $VE(m_1)$. Pega-se também na lista de pais de m_2 , o primeiro pai P_2 cujo valor de extinção é igual ou superior a $VE(m_1)$. Finalmente, a lista de inundação é atualizada, ou seja, P_2 é pai de P_1 com valor de extinção $VE(m_1)$.

A Figura 3.20 ilustra um exemplo de construção de lista de inundação para a mesma imagem sintética apresentada na Figura 3.5(a). Os valores indicam os níveis de cinza. Utiliza-se o volume como valor de extinção.

A primeira fusão ocorre entre os lagos 1 e 3 (Figura 3.20(b)). O valor de extinção do lago 3 é menor que o valor de extinção de 1. Portanto, o lago 1 inunda o lago 3. O mesmo processo se efetua para os lagos 2 e 4 (Figura 3.20(c)). A última fusão acontece entre os lagos 3 e 4 e cujo valor de extinção é igual a 8 correspondente ao lago 4. Isso significa que o lago que contém 3, formado pelos nós 1 e 3, inunda o lago que contém 4, formado pelos nós 2 e 4. Neste caso é preciso determinar o primeiro pai do lago 4 que possua valor de extinção maior que o valor de extinção da fusão ocorrida (lago 2). O




Figura 3.20: Exemplo de construção da árvore de inundação: (a) imagem original; (b) imagem dos mínimos rotulados; (c)-(d) seqüência de inundação; (e) lista de inundação.

mesmo deve ser feito para o lago 3, cujo pai é o lago 1. Por fim, associam-se os lagos 2 e 1, conforme mostra a Figura 3.20(d).

O contorno entre duas regiões é, então, determinado pelo maior valor do caminho presente na lista de inundação. Por exemplo, o valor do contorno entre as regiões 2 e 3 é igual a 8 e o contorno entre 1 e 2 também possui este mesmo valor.

3.5.3 Árvore dos lagos críticos

Ao contrário da lista de inundação, a quantificação dos contornos via ALC é efetuada após a aplicação da Transformada de Watershed. A análise é realizada tendo-se a ALC totalmente formada. A quantificação dos contornos é efetuada em dois momentos:

1. Análise direta — Quando as bacias se agrupam com o seu primeiro vizinho, como por exemplo as bacias 1 e 3 da Figura 3.21. Neste momento, é formado o lago crítico 6 e o valor do contorno 1–3 corresponde ao valor de extinção utilizado.
2. Análise via ALC — Quando as bacias se tocam com seus outros vizinhos, por exemplo as bacias 1 e 2 na Figura 3.21. Neste caso, pega-se o valor de extinção do primeiro pai comum às duas bacias (o nó 7) e associa-se ao valor do contorno 1 – 2.




Figura 3.21: Árvore dos lagos críticos para a imagem original em 3.20(a).




Figura 3.22: (a) Árvore geradora mínima para a imagem original em 3.20(a); (b) Contornos quantificados para a imagem exemplo estudada.

3.5.4 Árvore geradora mínima

A quantificação dos contornos através da árvore geradora mínima é possível graças a uma propriedade definida como segue.

Propriedade 1 *Quando uma bacia X toca um vizinho Y e esta aresta $X-Y$ não faz parte da árvore geradora mínima (AGM), é porque já existe um caminho na AGM que liga X a Y .*

Pode-se visualizar esta propriedade a partir da Figura 3.22. A propriedade diz que o custo de passagem entre as bacias 1 e 2 é maior que o custo entre 1 – 3, 3 – 4 e 4 – 2. Portanto, no momento da fusão entre 1 e 2, o referido caminho já existe.

Os valores dos contornos são, então, determinados do seguinte modo: para cada aresta que une as bacias que se tocam não pertencente à AGM, associa-se o maior valor de extinção presente no caminho dado pela AGM ao valor do contorno entre elas. Para a Figura 3.22, o valor do contorno entre as bacias 1 e 2 será calculado pela avaliação do caminho 1 – 3, 3 – 4 e 4 – 2, tomando-se o maior valor do volume (8 neste caso). Para as arestas presentes na AGM, a quantificação é direta. Para o cálculo do maior valor de um caminho em uma árvore pode-se utilizar o algoritmo de Dijkstra [82]. A imagem dos contornos é apresentada na Figura 3.22(b).




Figura 3.23: Exemplo de aplicação da metodologia de ALC para quantificação de bordas: (a) imagem original *buro*; (b)-(c) contornos quantificados (imagens em níveis de cinza – normal e sua negação); (d)-(f) resultado da limiarização de (c) para T igual a 100000, 50000 e 2000, respectivamente.

3.5.5 Resultados e discussões

A Figura 3.23 apresenta um primeiro resultado para as técnicas de quantificação de contorno, aplicadas na imagem *buro*. Os resultados são os mesmos para os três métodos explicados anteriormente e, portanto, uma análise da complexidade dos algoritmos se faz necessária para se efetuar uma comparação entre as metodologias. Os resultados a seguir foram obtidos através da análise via ALC. A segmentação multiescala via análise dos contornos é uma técnica interessante no sentido de que se pode trabalhar sobre uma imagem em nível de cinza (transição entre regiões) e após, escolher ou determinar um limiar T para obter a partição desejada.

Um outro resultado da quantificação de contornos para uma imagem clássica, o *camera man*, é ilustrado na Figura 3.24. A utilização de diferentes limiares permite suprimir determinados objetos semânticos na imagem.

As funções que implementam a quantificação dos contornos das regiões foram desenvolvidas no software MATLAB e executadas em um Pentium III 1.1 GHz. Para imagens de 256×256 e utilizando a ALC como representação, o




Figura 3.24: Obtenção de partições de uma imagem via aplicação da metodologia de ALC para quantificação de bordas: (a) imagem original *cameraman*; (b)-(d) partições obtidas via limiares 3000, 10000 e 250000, respectivamente, na imagem dos contornos em níveis de cinza.

processo completo (watershed, construção da ALC, determinação dos valores de cada contorno e mapeamento) levava cerca de 5min. Esse valor se deve à não otimização dos algoritmos e à codificação MATLAB. Os resultados podem ser obtidos em tempo real.

Capítulo 4

Casamento Hierárquico de imagens

Casar imagens é uma tarefa difícil e muitas vezes custosa computacionalmente. Em contrapartida, as aplicações no domínio de visão computacional são bastante vastas. Algoritmos de casamento de imagens são usados em problemas de perseguição de objetos, visão estéreo, reconhecimento de padrões, etc.

O problema de casamento de imagens torna-se um problema de casamento de grafos na medida em que as imagens são representadas por grafos e árvores. Nesta parte da tese, pretende-se levar a cabo um algoritmo de casamento de grafos que considere a informação hierárquica presente na estrutura das imagens. Para tanto, trabalha-se com a árvore dos lagos críticos (ALC), definida no capítulo anterior.

4.1 Introdução

O processo de comparar representações abstratas de imagens é uma grande tarefa no domínio da visão computacional. Uma representação consistente é dada pela teoria dos grafos, que fornece uma descrição estrutural do objeto [64]. Os grafos possuem a vantagem, por exemplo, de serem capazes de tratar diferentes problemas de transformações geométricas. Quando se representam imagens através de grafos, o problema de casamento de imagens torna-se um problema de casamento de grafos.

Conceitos básicos sobre grafos são vistos na Seção 3.2. Uma correspondência completa ou exata entre grafos é chamada de isomorfismo. Dois grafos G_1 e

G_2 são ditos isomórficos se existe uma relação biunívoca entre eles, ou seja, existe uma função f que associa os nós de G_1 aos nós de G_2 , além de outra função g que representa a associação entre as arestas, tal que se uma aresta e é incidente em $i, j \in G_1$, a aresta $g(e)$ é incidente em $f(i)$ e $f(j) \in G_2$. O problema do isomorfismo entre grafos é NP-completo¹ [82]. Pode-se dizer se dois grafos são isomórficos provando-se exatamente o contrário através do conceito de propriedades invariantes, por exemplo, o número de nós dos grafos. Essas propriedades são preservadas no isomorfismo.

A descrição de imagens por grafos pode ser contagiada por ruído e tornar-se bastante diferente mesmo para *frames* de uma mesma seqüência de vídeo, devido à inclusão ou ausência de alguns objetos. Portanto, o isomorfismo não pode ser alcançado e a correspondência entre grafos é normalmente incompleta. Contudo, pode-se determinar o grau de similaridade entre dois grafos, mas escolher ou criar este tipo de medida é um problema custoso [68].

A literatura no que se concerne ao problema de correspondência de grafos é bem abundante e os procedimentos para solucionar tal problema são bem diversificados. Dentre as diversas metodologias, pode-se citar métodos que usam equivalência entre valores próprios gerados a partir de uma *árvore de singularidade* [67]; algoritmos de busca do tipo A e A^* [69]; cálculo de funções de similaridade (ou dissimilaridade) entre dois grafos, incluindo as chamadas rotulações de processos de flexibilização probabilísticas e operações de edição de nós que permitem transformar um grafo G_1 em G_2 e onde a cada operação é atualizada uma função distância [64],[65],[66],[20]. Uma outra ordem de algoritmos, e que será melhor explicada nas seções seguintes, é a que utiliza o conceito de grafo associativo e a obtenção do máximo clique como solução para o problema da correspondência entre dois grafos [70]-[78]. Há trabalhos que combinam o uso de lógica fuzzy e grafos associativos na tentativa de obter uma melhor modelagem da imagem e para solucionar problemas decorrentes da segmentação [79],[80].

Alguns trabalhos em correspondências de grafos têm usado características da hierarquia associadas à modelagem de objetos a fim de obterem um diferente grafo associativo, menos denso em termos de quantidade de arestas [70],[71]. Uma representação bastante utilizada é denominada de *árvore de singularidade*. Esse tipo de árvore é construída a partir da análise da forma

¹Um problema é NP quando pode ser resolvido por algoritmos não-determinísticos em tempo polinomial [84]. A denominação de NP-completo tem a seguinte característica: *existe um algoritmo eficiente para um problema NP-completo se, e somente se, existirem algoritmos eficientes para todos os problemas NP-completos.*

das curvas das regiões presentes em uma imagem e normalmente é usada em imagens binárias.

O casamento de imagens desenvolvido neste capítulo está incluído na categoria descrita no parágrafo acima. Trabalha-se com a mesma estrutura definida no Capítulo 3, a árvore dos lagos críticos (ALC), cujos nós correspondem às regiões na imagem e cujas arestas correspondem a relações de vizinhança entre regiões.

Este capítulo está dividido em 4 seções. Inicia-se por uma breve caracterização do problema de correspondência entre grafos (Seção 4.2). O grafo associativo, uma estrutura relacional construída a partir das ALCs que se deseja corresponder, é definido na Seção 4.3. A Seção 4.4 apresenta o método responsável pela análise do grafo associativo e determinação da correspondência entre os nós das ALCs, denominado de clique máximo. Por fim, a Seção 4.5 aplica os conceitos de grafo associativo e determinação do clique máximo na perseguição do volume de sangue em imagens do ventrículo esquerdo do coração obtidas através do exame de ressonância magnética.

4.2 Caracterização do problema de correspondência entre grafos

Gomila em sua tese de doutorado [20] fez um interessante resumo da classificação da problemática relacionada ao casamento de grafos, conforme apresenta a Tabela 4.1. Esta tabela descreve todos os aspectos relacionados ao problema e à metodologia escolhida para a solução do problema, e são explicados a seguir:

- *Tipo da aplicação* — Define se o algoritmo será de uso geral ou dedicado.
- *Tipo do grafo* — Especifica a classe de grafo usada para modelar o objeto.
- *Restrições sobre a estrutura do grafo* — Particularidades adotadas em função do tipo do grafo.
- *Tipo dos atributos* — Indica como as características do objeto serão consideradas. É comum o uso de grafos ponderados.

- *Tamanho do grafo* — Importante aspecto que define a quantidade (ou uma faixa) de nós com a qual se irá trabalhar. Divide-se em menos de 100 nós (pequeno), entre 100 e 1000 nós (médio) ou mais de 1000 nós (grande).
- *Densidade das arestas* — Define a ordem da quantidade de arestas presentes no grafo: alta (maior que o quadrado do número de nós) e baixa (da mesma ordem do número de nós).
- *Tipo de casamento* — Relativo ao tipo de solução. O isomorfismo busca uma solução exata.
- *Categoria do algoritmo* — Lista alguns métodos de casamento.

O objetivo deste capítulo é levar a cabo um casamento de partições da imagem tendo como representação de imagem a árvore dos lagos críticos. Ela contém todo o conjunto de partições da imagem, informação que será útil nas etapas seguintes. Opta-se em trabalhar com grafos associativos e determinação do máximo clique, o maior subgrafo completo do grafo associativo. A densidade de arestas e o tamanho do grafo deverão ser fraca e pequeno respectivamente, devido à complexidade computacional do método. As Seções 4.3 e 4.4 explicam a forma de construção de um grafo associativo e obtenção do clique máximo, respectivamente.

4.3 O grafo associativo

O grafo associativo é uma das técnicas mais aplicadas na resolução de problemas de correspondência em visão computacional, e consiste na determinação da correspondência entre características ou regiões de *frames* consecutivos [83]. De forma geral, o grafo associativo é construído associando-se um nó a um mapeamento entre características das imagem do par estéreo (ou *frames* f_t e f_{t+1}) e uma aresta entre dois nós representa uma compatibilidade entre dois mapeamentos.

Neste trabalho, o Grafo Associativo $GA = (V, E)$ é o grafo gerado a partir de duas árvores dos lagos críticos $ALC_1 = (V_1, E_1)$ e $ALC_2 = (V_2, E_2)$ (ou simplesmente T_1 e T_2), onde o conjunto de vértices V é dado pelo produto cartesiano de V_1 e V_2 , ou seja,

$$V = V_1 \times V_2 \quad (4.1)$$

Tipo da aplicação	Específica Genérica
Tipo do grafo	Grafo de vizinhança de regiões Grafo de singularidade Outros
Restrições sobre a estrutura do grafo	Planar Árvores Outras
Tipo dos atributos	Nenhum Numérico Simbólico Estruturas
Tamanho do grafo	Pequeno Médio Grande
Densidade das arestas	Fraca Média Alta
Tipo de casamento	Exato Inexato
Categoria do algoritmo	Clique máximo árvores de busca, A ou A^* Redes Neurais Algoritmos genéticos Outros

Tabela 4.1: Classificação dos problemas de casamento de grafos.




Figura 4.1: Exemplo de construção de grafo associativo: (a) Árvore T_1 ; (b) Árvore T_2 ; (c) Grafo associativo entre T_1 e T_2 . Observe que não existe aresta entre os nós $(1, 1)$ e $(3, 1)$, já que no primeiro par o nó 1 de T_1 casa com o nó 1 de T_2 e, por conseguinte, o nó 3 de T_1 não poderia repetir a correspondência com o nó 1 de T_2 . Esse é um exemplo de incompatibilidade relacionado com o princípio da exclusão.

Portanto, observa-se que a quantidade de nós de GA é da ordem de $n \times m$, onde n e m são as quantidades de nós de ALC_1 e ALC_2 , respectivamente. Irá existir uma aresta entre dois nós do grafo associativo quando esta associação for consistente. A definição de consistência é dependente do problema e do tipo dos grafos usados na representação das imagens. Uma das primeiras restrições no estabelecimento de arestas entre nós é dada pelo princípio da exclusão. Este princípio estabelece a unicidade do casamento entre regiões, *i.e.*, uma região de uma imagem pode casar com somente uma outra região da imagem seguinte. A Figura 4.1 ilustra um grafo associativo construído a partir de duas árvores de 3 e 5 nós cada e respeitando o princípio da exclusão.

4.4 O clique máximo

O clique máximo é um problema clássico em otimização combinatorial e fornece uma solução para a tarefa de correspondência entre grafos. Apesar de ser um problema do tipo NP-completo, existem diversos grafos para os quais a solução é obtida em um tempo polinomial [70].

Dado um grafo associativo, um *clique* consiste em um sub-grafo no qual todos os nós são mutuamente adjacentes. O clique é dito *maximal* quando ele não está contido em um outro clique maior; clique *máximo* C_m é aquele que possui maior cardinalidade (número de nós) para um dado grafo associativo. No grafo associativo da Figura 4.1(c), são exemplos de cliques máximos C os sub-grafos formados pelos nós $\{(1, 1), (2, 2), (3, 3)\}$ e $\{(1, 3), (2, 4), (3, 5)\}$.

A correspondência de grafos que possuem atributos e/ou pesos nas arestas é a situação prática mais próxima do casamento de imagens reais. No caso de grafos $GA = (V, E, W)$, no qual o vetor W representa os valores dos atributos dos nós, procura-se determinar o clique máximo C_W cuja soma dos valores dos atributos é a maior possível, dada pela equação:

$$C_W = \max \left\{ \sum W(C_m) \right\} \quad \text{tal que } C_m \text{ é um clique de } GA \quad (4.2)$$

Os atributos dos nós do grafo associativo são gerados segundo a implementação de alguma medida de similaridade $\sigma()$ da seguinte forma:

$$W(u, v) = \sigma(\alpha_1(u), \alpha_2(v)) \quad (4.3)$$

Onde $u, v \in V$ e $\alpha_1()$ e $\alpha_2()$ são os atributos dos nós nos grafos originais que produzem o grafo associativo.

A literatura relativa à determinação de clique máximo é abundante e diferentes metodologias são propostas [70], [73], [74],[76]. Um bom panorama dos diversos métodos de obtenção de um clique pode ser visto no livro do Bomze [72]. Neste trabalho, utilizamos o método descrito por B. Yang [77], cuja idéia principal assemelha-se à estratégia de busca em profundidade, bastante comum em teoria dos grafos. O algoritmo de determinação de um clique é apresentado nos Algoritmos 3 e 4.

Para o caso de grafos associativos com pesos nas arestas, o trabalho de A. Branca [75] apresenta uma metodologia capaz de determinar o clique máximo.

Algoritmo 3 Determinação do clique máximo C_m de um grafo associativo.

Entrada: Grafo associativo $GA = (V, E)$ e número de nós n

$C \leftarrow \emptyset$ - cliques de GA
 $C_m \leftarrow \emptyset$ - clique máximo de GA
Rotular os nós de GA
Para cada nó i até n **Faça**
 Se rótulo(i) = i **Então**
 $C \leftarrow i$ % nova raiz de um clique
 Fim Se
 CLIQUE(C, i, V)
 Se C é maximal **Então**
 $C_m \leftarrow C$
 Fim Se
Fim Para

Algoritmo 4 Função CLIQUE (C, k, V)

Para cada nó $j \leftarrow k + 1$ até n **Faça**
 Se nó j é vizinho de todos os nós em C **Então**
 $C \leftarrow C + \{j\}$
 rótulo(j) = rótulo(k)
 CLIQUE(C, j, V)
 Fim Se
Fim Para

4.5 Aplicação na perseguição do volume de sangue do ventrículo esquerdo em imagens de ressonância magnética

4.5.1 Introdução

Perseguição de objetos é o processo de estimar automaticamente o estado corrente de um objeto baseado no estado anterior. Objeto (ou *objeto de vídeo*) representa uma entidade semântica em uma sequência de imagens e, normalmente, sua definição envolve considerações semânticas. Apesar da larga aplicação em processamento de imagens, perseguir um objeto não é uma

tarefa fácil em função de problemas de iluminação, indefinição de contornos, definição da semântica etc; por outro lado, realizar essa tarefa através de interação direta do usuário é impraticável devido à grande quantidade de dados envolvida. Esta seção apresenta um método para perseguir objetos em seqüências de imagens de Ressonância Magnética — MR, do coração (obtidas através de uma técnica chamada *cine MR*). O objeto de interesse é a porção de sangue contida no ventrículo esquerdo, adequada à análise e avaliação de diversos parâmetros cardiológicos, como por exemplo o volume *stroke*.

A segmentação do ventrículo pode ser efetuada através de diferentes metodologias, tais como técnicas baseadas em contornos ativos, limiarização adaptativa e classificação de pixel e/ou de região (o leitor poderá consultar Rondina [21] para uma explanação mais completa dos métodos). Esses métodos são usados seja para a segmentação do volume de sangue, seja para a segmentação do músculo miocárdio. Normalmente, a segmentação envolve alguma interação com o usuário, principalmente para prover as condições iniciais do método adotado.

Nas próximas seções, é apresentada uma solução para o problema da segmentação do volume de sangue no ventrículo esquerdo em seqüências de imagens *cine MR*. A solução baseia-se em duas etapas: (i) representação dos *frames* através da árvore dos lagos críticos, descrita no capítulo anterior; (ii) determinação da correspondência entre ALC's através do grafo associativo e do clique máximo. Essa metodologia é aplicada para um conjunto de imagens obtidas junto ao Incor — *Instituto do Coração*, de São Paulo.

4.5.2 Grafo associativo e determinação do clique

A fim de reduzir a densidade de nós e arestas e de explorar as propriedades hierárquicas da árvore dos lagos críticos, iremos introduzir novos critérios na construção do grafo associativo $GA = (V, E)$.

No que diz respeito à determinação dos nós, utiliza-se o *princípio da proximidade* para reduzir a quantidade de nós de GA . Este princípio consiste em calcular a distância entre pontos característicos das regiões que formam o par correspondente no GA , normalmente o centróide, aplicando em seguida um limiar para essa distância. O princípio da proximidade é válido desde que não haja um grande movimento entre *frames* consecutivos [76]. A métrica de distância escolhida foi a distância euclidiana d_E , calculada segundo a equação:

$$d_E = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (4.4)$$

onde (x_1, y_1) e (x_2, y_2) representam as coordenadas dos centróides das regiões nos *frames* 1 e 2, respectivamente.

Para a redução da densidade de arestas, utilizam-se dois critérios além do princípio da exclusão: o critério do *caminho orientado* e o *princípio da rigidez*.

O critério do caminho orientado (*path string criterion* — *str* ()) [70], [71], diz que a relação de vizinhança para quaisquer dois nós (u, w) e (v, z) em V é obtida através da equação:

$$(u, w) \sim (v, z) \Leftrightarrow str(u, v) = str(w, z) \quad (4.5)$$

Onde o sinal $\sim$ representa adjacência entre os nós. A função *str* () representa o conceito de caminho orientado em uma árvore hierárquica. Em uma árvore, somente dois tipos de movimento podem ser realizados: para cima ou para baixo, designados por +1 e -1, respectivamente. Portanto, o caminho orientado entre dois nós u e v é o conjunto de todos os movimentos necessários para atingir o nó v , partindo-se de u . Na Figura 4.1(b), o caminho orientado do nó 5 até o nó 1 é $str(5, 1) = \{-1, -1\}$. O caminho orientado pode ser obtido a partir das matrizes distância das árvores que se deseja casar [70]. Seja $u, v \in V_1$ e $w, z \in V_2$. Então, $str(u, v) = str(w, z)$ se, e somente se, as condições abaixo forem satisfeitas:

$$d(u, v) = d(w, z) \quad (4.6)$$

$$lev(u) - lev(v) = lev(w) - lev(z) \quad (4.7)$$

onde $d(x, y)$ é a distância entre dois nós da ALC^2 , como explicada na Seção 3.2, e $lev(x)$ representa o nível de cada nó, ou seja, a distância do nó x até a raiz da árvore a qual ele pertence.

O critério do caminho orientado tem uma importância relevante no casamento de árvores hierárquicas. Especificamente para a ALC , o critério impede a correspondência de regiões presentes em partições de nível elevado com regiões próximas às folhas. Não faz sentido em uma imagem originalmente com 1000 regiões, por exemplo, casar uma microbacia gerada pelo watershed (partição mais fina) com as regiões presentes em uma partição com 20 ou 10

²Essa distância é calculada normalmente através do algoritmo de Dijkstra [82].




Figura 4.2: Grafo associativo da Figura 4.1(c) após o uso do critério do caminho orientado.

regiões. O caminho orientado também é usado como uma medida do grau de similaridade entre dois grafos [63]. A Figura 4.2 apresenta o grafo associativo formado a partir das árvores T_1 e T_2 da Figura 4.1(a),(b), utilizando os princípios da exclusão e o critério do caminho orientado.

O princípio da rigidez estabelece que a distância entre centróides (ou pontos característicos) de regiões do mesmo *frame* é aproximadamente constante nos *frames* subsequentes [76]. Desta forma, existe compatibilidade entre dois nós (u, w) e (v, z) se a distância entre u e v for aproximadamente a mesma distância entre w e z . Mais uma vez foi escolhida a métrica euclidiana para o cálculo das distâncias.

Para o problema do clique máximo, utilizam-se os Algoritmos 3 e 4 com a devida modificação para tratar do caso de clique máximo com atributos nos nós. Basicamente, trata-se da inclusão de mais uma variável responsável pelo armazenamento da soma dos valores dos atributos, como indicado pela Equação 4.2.

4.5.3 Experimentos e resultados

Os resultados apresentados foram obtidos em uma máquina Pentium III 1.1 GHz, com 256 MB de memória, rodando o sistema operacional Windows. Também foram utilizadas estações SUN Ultra 1, rodando SunOS com 64 MB de memória. As funções e *scripts* foram desenvolvidos em *MATLAB*, cuja versão instalada é a 6.0, utilizando-se de funcionalidades presentes na *toolbox* de Morfologia Matemática da *SDC Morphology*.

A seqüência de imagens do ventrículo esquerdo foi cedida pela Divisão de Informática do InCor — Instituto do Coração de São Paulo, primeiramente ao trabalho de mestrado da aluna Jane Rondina [21], no DCA/UNICAMP. As seqüências possuem 144 *frames*, divididas em 9 fatias (espacial) e 16 fases (temporal), e foram gravadas originalmente no formato TIM (111 x 115 pixels).

Alguns experimentos são ilustrados pelas Figuras 4.3-4.5. Normalmente, uma imagem de ventrículo possui mais de 2000 regiões e classes. A correspondência entre as regiões de interesse de *frames* consecutivos era realizada em cerca de 30s. Contudo, os resultados podem ser obtidos em tempo real caso se utilize a Linguagem C e os algoritmos sejam otimizados.

Um primeiro experimento é feito escolhendo-se uma partição específica da imagem, a fim de reduzir o espaço de escalas e conseqüentemente a quantidade de regiões a serem casadas. O nível P_k com 7 regiões (ao todo, a ALC ficará com 13 nós) foi o escolhido, pois para a maioria dos *frames*, nesta partição uma classe corresponde ao volume de sangue que se deseja determinar. A Figura 4.3(a) apresenta uma parte da seqüência original com 8 *frames*. O uso do grafo associativo na forma tradicional (Seção 4.3) produziria um grafo com 169 nós e alta densidade de arestas (mais de 100 arestas por nó) para cada par de imagens. Através do uso de critérios mais restritivos, como os princípios da proximidade, rigidez e o caminho orientado, chega-se a um grafo associativo com baixa densidade de arestas e obtém-se uma redução dos nós de mais de 50%. A Figura 4.3(b) apresenta a seqüência recuperada da porção de sangue, via casamento através da construção do grafo associativo e determinação do clique máximo.

Os dendrogramas dos *frames ventr017* e *ventr018* são dados na Figura 4.4(a),(b), respectivamente. O processo de construção do grafo associativo (apresentado nas Figuras 4.4(c),(d)) segue a seguinte ordem:

1. determinação dos nós de GA — Uso do princípio da proximidade: caso d_E seja menor que uma tolerância T_1 , o nó é válido.




Figura 4.3: (a) Seqüência de 8 fatias do ventrículo esquerdo (*ventr011-ventr018*); (b) seqüência com a região de interesse, definida na primeira fatia e recuperada nas fatias subseqüentes via casamento; (c) imagens (a) e (b) sobrepostas.

2. determinação das arestas de GA — O primeiro critério a ser utilizado é o princípio da exclusão. Em seguida, aplica-se o critério do caminho orientado e, por último, o princípio da rigidez (tolerância T_2).

Os algoritmos de determinação do clique máximo tiveram também que ser adaptados ao *MATLAB*, já que esta ferramenta não trabalha com algoritmos recursivos. Outro exemplo da aplicação do uso desta metodologia é apresentado na Figura 4.5 para uma diferente fase da seqüência de imagens.

Infelizmente, a porção de sangue nem sempre se encontra na mesma partição para todos os *frames* da seqüência. Por isso, é interessante ressaltar uma importante característica da ALC (diferentemente da técnica apresentada em [20], por exemplo) aplicável em problemas de casamento de regiões de imagem. Quando se escolhe uma partição, como feito no experimento apresentado, na verdade se trabalha com toda a seqüência de partições $P_7, P_6 \dots P_1$. Essa técnica permite tratar de erros de segmentação, quando acontece de um objeto semântico ser representado por 1 região em um *frame* e por 2 (ou mais) regiões em *frames* subseqüentes. Essa idéia é similar à apresentada por López *et al.* [78], com a diferença de que no trabalho




Figura 4.4: (a),(b) Dendrogramas das imagens de ventrículos *ventr017* e *ventr018*, respectivamente, e seus (c),(d) grafos associativos para $T_1 = 30$ e $T_1 = 20$. Note a redução da densidade de arestas com a diminuição da tolerância do princípio da proximidade. Infelizmente se torna inviável a ilustração de um grafo associativo sem o uso de critérios tão restritivos, em função da alta densidade de arestas.

de López, a estrutura que representa a imagem não é hierárquica. Além disso, no trabalho de López a fusão entre regiões é comandada por uma operação de limiarização, cujo parâmetro é definido pelo usuário. Significa que a fusão pode não contemplar todas as possibilidades de combinações de regiões. O problema dos erros de segmentação é, então, solucionado através da construção e análise do grafo associativo, denominado de *grafo associativo de incompatibilidades*. Obviamente, com o uso desta metodologia baseada na construção de hierarquia não é necessária a redefinição do grafo associativo, já que a *ALC* fornece de forma natural todas as possíveis fusões entre regiões da imagem.




Figura 4.5: (a) Seqüência de 8 fatias do ventrículo esquerdo (*ventr029-ventr036*); (b) seqüência com a região de interesse, definida na primeira fatia e recuperada nas fatias subseqüentes via casamento; (c) imagens (a) e (b) sobrepostas.

O critério do caminho orientado é bastante restritivo no que diz respeito à compatibilidade entre pares de nós e, por conseguinte, no estabelecimento da correspondência. A *ALC* pode sofrer grandes variações em sua topologia, mesmo para *frames* vizinhos, como mostram por exemplo os dendrogramas das Figuras 4.4(a) e (b). Isso pode impedir que regiões presentes em níveis próximos da hierarquia possam ser casadas no processo de determinação do clique. Portanto, uma possível solução para esse problema é a flexibilização do critério do caminho orientado, definido pelas Equações 4.6 e 4.7, e reescritas da seguinte forma:

$$|d(u, v) - d(w, z)| = NR \quad (4.8)$$

$$lev(u) - lev(v) - (lev(w) - lev(z)) = NR \quad (4.9)$$

onde NR representa a quantidade de níveis de flexibilização do critério do caminho orientado.

A Figura 4.6 ilustra uma idéia de flexibilização do critério do caminho orientado. As Figuras 4.6(a), (b) apresentam as árvores originais T_1 e T_2 a serem casadas e em (c), o grafo associativo *relaxado*. As arestas tracejadas




Figura 4.6: Exemplo de construção de grafo associativo com flexibilização: (a) Árvore T_1 ; (b) Árvore T_2 ; (c) Grafo associativo com flexibilização entre T_1 e T_2 (as arestas tracejadas foram incluídas pelo processo de flexibilização do critério do caminho orientado).

são aquelas que respeitam o critério do caminho orientado, com flexibilização. Neste novo grafo associativo, usou-se uma flexibilização de 1 nível: isso implica em dizer que se o nó 1 da árvore T_1 casar com o nó 1 da árvore T_2 , o nó 2 de T_1 pode corresponder aos nós 2 ou 3 (mesmo nível) ou 4 (1 nível a mais) de T_2 . Na flexibilização a reciprocidade não existe, ou seja, caso o nó 1 da árvore T_1 corresponda ao nó 4, o nó 2 de T_1 não pode casar com o nó 1 de T_2 .

A Figura 4.7 apresenta um resultado cujo grafo associativo foi construído com uma flexibilização de 1 nível no critério do caminho orientado. As imagens originais são duas fatias do ventrículo esquerdo do coração (*ventr041* e *ventr042*), mostradas nas Figuras 4.7(a) e (b). A ordem da matriz de adjacência do grafo associativo sem a flexibilização do critério do caminho orientado, apresentado na Figura 4.7(c), foi de 65×65 (usando o princípio da proximidade entre os nós); com a flexibilização, a ordem aumentou em

cerca de 3 vezes. É preciso cautela no uso da flexibilização, pois se de certa forma possibilita o casamento entre regiões em diferentes níveis na árvore dos lagos críticos e, portanto, o tratamento de erros no processo de segmentação em imagens, por outro lado a densidade das arestas do grafo associativo também aumenta consideravelmente. Isso demanda maior poder computacional para a determinação do clique máximo. As regiões de interesse das imagens *ventr041* e *ventr042* são mostradas nas Figuras 4.7(d) e (e).




Figura 4.7: (a)-(b) Fatias originais do ventrículo esquerdo *ventr041* e *ventr042*; (c) Grafo associativo construído sem a flexibilização do critério do caminho orientado; (d)-(e) imagem com as regiões de interesse de (a) e (b), definidas via casamento das imagens originais; (f) imagens (a) e (d) sobrepostas; (g) imagens (b) e (e) sobrepostas.

Capítulo 5

Análise do espaço de escalas

A utilização de hierarquias na representação de imagens, como visto no Capítulo 3, permite trabalhar com partições que vão do nível mais fino ao mais grosseiro. Este modelo constitui o espaço de escala gerado pela Árvore dos Lagos Críticos – ALC.

Este capítulo é consagrado à segmentação de imagens com base na análise do espaço de escalas. A análise é feita através da avaliação de atributos calculados para todos os nós (regiões) da ALC. Exemplos de tais atributos podem ser classificados em hierárquicos (tempo de vida), níveis de cinza (média, variância), geométricos e morfológicos (área, perímetro, volume). O capítulo apresenta ainda uma aplicação na segmentação de imagens de células de leveduras, em colaboração com a Faculdade de Engenharia de Alimentos da UNICAMP

5.1 Introdução

Representações baseadas em espaço de escalas têm grandes aplicações em tarefas ligadas a visão computacional e reconhecimento de padrões. Elas levam em consideração que os objetos reais podem ser interpretados hierarquicamente e existem sob uma determinada faixa do espaço de escalas [29], [30]. Dessa afirmação surge a seguinte questão: em que níveis de escala (e como determiná-los) o objeto ou região de interesse pode ser encontrada?

A teoria de espaço de escalas, que trata das representações multiescala, tenta responder essa pergunta através da análise de determinados parâmetros ou atributos que modelam o objeto de interesse. A análise é feita em todo o espaço de escalas já que normalmente não se tem informação *a priori* sobre

em qual escala (ou faixa) o objeto se encontra. Portanto, o processo de discriminação de objetos através da teoria de espaço de escalas consiste em três etapas: obtenção da representação multiescala, extração ou cálculo de parâmetros e análise dos parâmetros de acordo com o objeto de interesse. Existem diversas metodologias que geram representações multiescala de uma imagem. Apresentam-se algumas nos parágrafos seguintes.

Uma das primeiras e mais comuns abordagens na teoria de espaço de escalas foi a filtragem Gaussiana [30]. A filtragem Gaussiana é definida através da convolução de uma imagem com um *kernel* gaussiano de dimensão variável. Contudo, a idéia básica desta teoria é originária do início da década de 70 [29], quando alguns pesquisadores usavam operadores de diferentes tamanhos na detecção de bordas ou representavam imagens em diferentes níveis de resolução, através de sub-amostragem. Na década de 80, as *Wavelets* [31] tornaram-se uma importante ferramenta na representação multiescala de imagens. A idéia básica da Transformada de Wavelet (ondaletas, em português) é a mesma da Transformada de Fourier, ou seja, representar uma função através de uma combinação linear de ondaletas ou senos e cossenos, respectivamente. A Transformada de wavelet é localizada no tempo (ou espaço), além de possuir uma função de escala que permite efetuar dilatações ou compressões nas funções base das ondaletas. Ondaletas são funções que satisfazem determinadas propriedades, podendo ser simétricas ou não, e sua escolha depende da aplicação a qual se destinam.

Diversos trabalhos consideram a construção de um espaço de escalas através de operações morfológicas. Kothe [30] define um espaço de escalas através das operações abertura, para escalas positivas, e fechamento morfológicos, para escalas negativas. Meyer e Maragos [32] e Vachier [33] usam *levelings* na obtenção da sua representação multiescala. *Levelings* são uma classe de operadores morfológicos tais que dados os *pixels* vizinhos x e y , uma imagem g é um *leveling* da imagem f se a relação a seguir for verificada:

$$g_x > g_y \Rightarrow f_x \geq g_x \text{ e } g_y \geq f_y \quad (5.1)$$

Um operador conexo é um *leveling* de qualquer outra função [33]. Outro espaço de escala não-linear é o construído por Jackway [34] através de dilatações e erosões sucessivas com diferentes tamanhos de elementos estruturantes. Este tipo de operação possui a desvantagem de deslocar os contornos dos objetos [32].

Visto que no Capítulo 3 tratou-se da geração da Árvore dos Lagos Críticos

e que essa árvore constitui uma representação multiescala de imagens, este capítulo aborda a extração e análise de características relacionadas ao objeto de interesse a partir da ALC.

Este capítulo é organizado da seguinte forma. A Seção 5.2 apresenta as propriedades e paradigmas que um espaço de escalas deve observar, além das evidências de que a representação adotada os satisfaz. Em seguida, apresenta-se na Seção 5.3 uma metodologia geral e exemplos de segmentação de imagens baseados na análise do seu espaço de escalas. Por fim, desenvolve-se uma aplicação desta técnica na discriminação de células de leveduras, em colaboração com a Faculdade de Engenharia de Alimentos da Unicamp. Leveduras constituem uma importante espécie de fungo utilizada em vários processos químicos e a aplicação em questão é detalhada na Seção 5.4.

5.2 Paradigmas e propriedades de um espaço de escalas

A fim de bem descrever um espaço de escalas, é necessário que este satisfaça uma série de características, como especificadas a seguir. Essas características garantem uma análise coerente e consistente do espaço nas tarefas a que ele se destina.

Uma característica básica de qualquer espaço de escalas é que estruturas em escalas mais altas devem ser mais simples do que estruturas em escalas mais finas [29], [32], como ilustrado na Figura 5.1. Além disso, as estruturas em escalas mais altas devem ser geradas através da simplificação das estruturas em níveis inferiores. Esse é o princípio da causalidade.

Alguns espaços de escalas apresentam propriedades de linearidade e invariância ao deslocamento. Essas propriedades são originárias de representações lineares, como a que utiliza filtros Gaussianos [29]. Um grave problema deste tipo de representação é que a filtragem de uma imagem através de filtros Gaussianos suaviza a imagem uniformemente, incluindo as suas bordas. Portanto, os contornos ficam borrados e a localização dos objetos de interesse pode tornar-se imprecisa [32], [33].

Em representações não-lineares, como por exemplo o *watershed*, o problema citado no parágrafo anterior não existe. Uma outra vantagem do *watershed* é que se trata de uma transformação isotrópica, ou seja, é invariante à rotação. Essa característica é interessante, por exemplo, na recuperação de




Figura 5.1: Representação de um espaço de escalas: estruturas em níveis mais elevados devem ser simplificações delas mesmas em níveis inferiores.

informação em bases de dados.

As representações multiescala também não devem criar novas estruturas em escalas mais elevadas, como é o caso de contornos e extremos regionais [33]. Isso implicaria na introdução de ruídos na imagem e dificultaria a sua análise.

A Árvore dos Lagos Críticos satisfaz todas as propriedades de um espaço de escalas citadas anteriormente. A escala mais fina desta representação, correspondente às folhas da ALC, é gerada a partir do *watershed*. As escalas de níveis superiores são formadas pelo agrupamento de duas regiões da escala anterior, até a obtenção de uma imagem com somente uma região. Portanto, garante-se a simplificação progressiva das escalas, além do princípio da causalidade. O *watershed* é conhecidamente uma transformação que não gera novos contornos ou extremos na imagem, sendo os primeiros determinados pelo gradiente morfológico. O que acontece nessa representação é a eliminação progressiva de contornos e mínimos regionais menos importantes, segundo um dado critério, a medida em que o nível da escala aumenta.

5.3 Segmentação de imagens via análise do espaço de escalas

Uma vez especificado o espaço de escalas em que se irá trabalhar e a forma de representá-lo, resta definir o procedimento a ser adotado na sua análise para realização de segmentação de imagens. O espaço de escalas gerado pela ALC consiste em uma hierarquia, representada por uma árvore cujas folhas correspondem às regiões na imagem rotuladas pelo *watershed*, as quais iremos chamar somente de *regiões*. Os outros nós da árvore são construídos pela fusão de regiões, duas a duas, para os quais iremos adotar a notação *classes*, originária da taxonomia.

Basicamente, a metodologia geral de análise do nosso espaço de escalas é dividida em duas etapas: (i) cálculo dos atributos de regiões e classes e (ii) análise hierárquica dos atributos.

5.3.1 Cálculo dos atributos

Os atributos têm um papel importante na segmentação de objetos, pois eles descrevem características particulares para cada aplicação. A escolha de atributos adequados pode vir a simplificar o processo de segmentação ou classificação de objetos, no que diz respeito, por exemplo, à eliminação de informação redundante ou simplesmente desnecessária. Os atributos podem ser agrupados em diferentes classes, sendo algumas descritas a seguir.

- *Morfológicos* – Relacionados à forma dos objetos. Ex.: fator de forma, esqueletos.
- *Níveis de cinza* – Relativos à resolução em níveis de cinza da imagem. Ex.: média, valores máximos e mínimos, variância.
- *Geométricos* – Relacionados à geometria do objeto. Ex.: área, volume.
- *Dependentes da escala* – Provenientes da análise da representação hierárquica. Ex.: tempo de vida, nascimento, morte.

Dentre os atributos citados acima, os atributos dependentes da escala e característicos das representações hierárquicas merecem uma explicação adicional. Nascimento e morte de regiões ou classes são definidas a seguir.

Definição 1 (Nascimento e morte de regiões e classes) *Seja uma imagem representada através de um dendrograma indexado (DI). Nascimento (B - birth) e morte (D - death) correspondem aos índices no DI em que as regiões e classes surgem ou desaparecem através da fusão com outras regiões ou classes, respectivamente.*

Após definidos *nascimento* e *morte*, o *tempo de vida* de uma região ou classe é dado como segue.

Definição 2 (Tempo de vida) *Seja uma imagem representada através de um DI. Tempo de Vida (ST - survival time) corresponde a "idade" de uma região ou classe. Para regiões, o ST é o índice no DI em que estas são fusionadas pela primeira vez. Para classes, o ST corresponde à diferença entre dois índices no DI: nascimento e morte.*

A Figura 5.2 apresenta um exemplo de dendrograma para fins ilustrativos das definições das propriedades dependentes da escala citadas acima.




Figura 5.2: (a) Exemplo de dendrograma e (b) sua representação matricial. Na matriz, as duas primeiras colunas são os rótulos das regiões e classes e a terceira coluna, o índice hierárquico.

Na Tabela 5.1 apresentam-se os valores dos atributos nascimento(B), morte(D) e tempo de vida(ST) para as regiões e classes (R/C) do dendrograma da Figura 5.2. Observe que para a classe de rótulo 17, que representa a raiz do dendrograma (uma imagem com uma só região), o tempo de vida é infinito em função dela não desaparecer. O atributo ST pode fornecer

indícios de que uma região ou classe é importante no processo de segmentação, no sentido que um objeto que permanece isolado por muito tempo pode ser significativamente diferente dos outros.

R/C	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
B	0	0	0	0	0	0	0	0	0	3	5	6	7	8	10	13	17
D	5	5	3	3	6	6	7	8	13	10	17	7	8	10	13	17	–
ST	5	5	3	3	6	6	7	8	13	7	11	1	1	2	3	3	∞

Tabela 5.1: Tabela com valores dos atributos nascimento (B), morte (D) e tempo de vida (ST) para as regiões e classes (R/C) do dendrograma da Figura 5.2.

É interessante notar a correspondência entre as definições desses atributos dependentes de escala e as nomenclaturas usadas na morfologia matemática. O atributo *morte*, por exemplo, corresponde ao *valor de extinção* de uma região ou classe, como definido no Capítulo 3, e constitui uma medida de persistência do objeto.

5.3.2 Análise dos atributos

A complexidade em se realizar segmentação de imagens através da análise do espaço de escalas requer, geralmente, a utilização de vários atributos, sejam de uma mesma classe ou combinações entre atributos de classes diferentes. Contudo, uma metodologia genérica de escolha e análise destes atributos ainda não foi desenvolvida e, portanto, as análises normalmente são feitas para aplicações específicas.

A representação multiescala será analisada de forma hierárquica, no sentido de efetuar a análise dos atributos mais restritivos aos menos restritivos. O objetivo é eliminar alguns nós da *ALC* próximos às folhas, que normalmente constituem ruídos na imagem, e nós próximos à raiz, que representam objetos com grandes áreas e sem significado semântico. A Figura 5.3 apresenta um esquema ilustrativo da análise a ser realizada no espaço de escalas.

Os critérios dependentes da escala são poderosos e normalmente são usados no início da análise hierárquica em função da grande redução de nós da *ALC*. Na outra extremidade da análise, encontram-se os critérios que utilizam atributos relacionados aos níveis de cinza, que são genéricos e sujeitos




Figura 5.3: Esquema representativo da análise dos atributos. Na imagem à esquerda têm-se várias partições de uma imagem $P_0, P_1, \dots, P_n$, onde as regiões de interesse são as de nível de cinza branco, com formas ovais. Após a análise dos atributos, as regiões de interesse são determinadas (imagem da direita).

a variações devido às mudanças na iluminação ou interferências geradas no processo de aquisição da imagem. No meio termo, encontram-se os critérios que utilizam atributos que descrevem características singulares dos objetos a serem segmentados, tais como forma ou área.

O passo seguinte à análise é reconstruir a imagem utilizando-se dos nós da *ALC* que satisfizerem os critérios especificados. A reconstrução é realizada supondo-se as regiões ou classes (nós) como camadas que devem ser sobrepostas. Portanto, deve-se percorrer o espaço completo, identificando os nós em cada partição e adicionando-os à imagem resultante. Esse processo é apresentado no Algoritmo 5.

5.3.3 Resultados em imagens

Os exemplos seguintes ilustram a aplicação dessa metodologia em imagens reais. A Figura 5.4 apresenta uma imagem de arroz e 3 resultados da aplicação do watershed hierárquico, calculando-se partições da imagem com 70, 80 e 90 regiões. O objetivo é separar os grãos de arroz contidos na imagem

Algoritmo 5 Obtenção da imagem segmentada após análise dos atributos.

 $I \leftarrow$ Imagem resultante $N \leftarrow$ Lista dos nós resultantes da análise $P \leftarrow$ Partição da imagem original**Enquanto** $N \neq \emptyset$ **Faça** Selecionar $N(1)$ Calcular P a qual pertence $N(1)$ Determinar a região ou classe RC em P correspondente a $N(1)$ Atualizar I com RC Remover $N(1)$ de N **Fim Enquanto**

original da Figura 5.4(a).

Infelizmente, não é possível identificar com precisão qual a partição que melhor representa a segmentação da imagem *arroz 1*. Esse é um dos casos onde a análise do espaço de escalas se mostra como uma boa solução para o problema de segmentação. A Figura 5.5 mostra o resultado da análise da imagem *arroz 1*, para várias configurações, além da imagem final binarizada. As siglas *ST*, *NC* e *A* representam os critérios tempo de vida, média do nível de cinza da região e área da região, respectivamente.

Uma tarefa difícil na análise é a escolha dos atributos que são importantes para discriminar os grãos de arroz, ou, de maneira geral, para discriminar o objeto de interesse. Para o caso de utilizarem-se vários atributos e sabendo-se que alguns deles já seriam suficientes na análise, existem estudos de classificação que calculam o peso de cada atributo na discriminação do objeto, como por exemplo, o trabalho que utiliza variáveis canônicas [59].

5.4 Aplicação na segmentação de leveduras

5.4.1 Fundamentos

Os fungos constituem um grupo de microorganismos que têm grande interesse prático e científico. Os fungos são organismos que obtêm sua alimentação da matéria orgânica inanimada ou nutrindo-se como parasitas. A atividade fúngica é responsável, por exemplo, pela fertilidade do solo. Os fungos também são importantes na atividade industrial, em processos de fermen-




Figura 5.4: Exemplos da segmentação de imagens via análise do espaço de escalas: (a) Imagem original *arroz 1*; (b) watershed hierárquico com 70 regiões; (c) watershed hierárquico com 80 regiões; (d) watershed hierárquico com 90 regiões.

tação presentes na fabricação de cervejas, vinho, produção de antibióticos, vitaminas e ácidos orgânicos.

De modo geral, os fungos são divididos em bolores e leveduras [36]. A classificação como bolor é usada para designar os mofos, as ferrugens e o carvão (doença de gramíneas).

A palavra *levedura* é proveniente do latim *levere* e é empregada como sendo equivalente a *levedo*, para designar fermentação ou um grupo de fungos [37]. As leveduras são fungos que se apresentam predominantemente sob forma unicelular e sua reprodução se faz normalmente por gemulação. Quando a levedura gêmula estiver com tamanho aproximado ao da célula-mãe, forma-se uma parede transversal entre ambas. A importância das leveduras está associada à fermentação de sucos de frutas, pão, cerveja, além de




Figura 5.5: Análise do espaço de escalas para a imagem *arroz 1*: (a) $ST > 500$, $(300 < A < 900)$ e $NC > 110$; (b) $ST > 200$, $(300 < A < 900)$ e $NC > 110$; (c) $ST > 100$, $(200 < A < 900)$ e $NC > 110$; (d) Uma possível solução, binarizada, eliminando-se pedaços não significativos de grãos de arroz.

outros alimentos. A Taxonomia desses microorganismos está em constante alteração em função do progresso em diversos setores, como por exemplo, os avanços ocorridos na microscopia eletrônica e técnicas de processamento de imagens. Normalmente, a classificação das leveduras se baseia no estudo das características macro (cor, consistência, bordas, topografia, superfície) e micromorfológicas (reprodução, forma e tamanho das células, entre outros).

O leitor poderá encontrar um pouco da história, além de definições básicas e uma completa caracterização das leveduras em [36],[37].

Nas últimas décadas, o uso de equipamentos automáticos na análise de leveduras tem crescido continuamente, com o objetivo de mensurar características qualitativas e quantitativas, a fim de estudar a relação entre mor-

fologia das células e produtividade [40]. Alguns trabalhos que usam técnicas de processamento de imagens na segmentação e classificação de leveduras são dados em Pons [38]-O'Shea [41].

Em [38], Pons *et al.* usam binarização seguida de dilatação, operações de preenchimento de buracos e erosões na segmentação de leveduras. Essas operações garantem que a célula se torne fechada. Características iniciais na captura das imagens são controladas pelo usuário, que ajusta brilho, contraste e foco do microscópio. No referido trabalho, é usado um software chamado *Visilog* que incorpora esse procedimento de segmentação e cálculo de parâmetros das células, que serão usados para uma futura classificação do seu tipo.

O'Shea [39] também usa basicamente a limiarização como forma de gerar uma imagem segmentada inicial. Em seguida, várias operações de dilatação e erosão, preenchimento de buracos e removimento de pequenos ruídos são efetuadas no pós-processamento da imagem inicial. Além disso, O'Shea sugere uma classificação morfológica em 6 classes para leveduras do tipo *Kluyveromyces marxianus* var. *marxianus* NRRLy2415. Em um trabalho mais recente, O'Shea [41] acrescenta uma classe ao mesmo tipo de levedura. A análise das imagens é feita através do mesmo sistema desenvolvido em [39].

Em [40], Zalewski propõe um método baseado na obtenção de contornos externos e internos das células (tratamento de contornos). Essa operação é feita após uma filtragem por similaridade de cor. Com o intuito de preencher buracos gerados pelos tratamentos de contornos e filtragem de cor, é também realizada uma subamostragem da imagem.

De fato, essas operações são extremamente dependentes dos valores de cinza das células. Os procedimentos descritos necessitam de uma forte interação e supervisão do usuário durante todo o processo. Além disso, a detecção de bordas como descritas nesses trabalhos e limiarização podem não preservar exatamente os contornos das leveduras. A operação dilatação pode provocar a união de ruídos e, desta forma, criar células inexistentes.

A idéia de utilizar análise hierárquica na segmentação de leveduras surgiu de um contato efetuado entre um aluno da Faculdade de Engenharia de Alimentos da Unicamp e o Prof. Roberto Lotufo. O projeto de tese do doutorando Bernardo Yépez [42] tem como objetivo definir a relação que existe entre os parâmetros de engenharia de processo e o comportamento metabólico e morfológico de uma levedura, chamada *Kluyveromyces marxianus*, visando esclarecer mecanismos de produção de enzimas (inulinase). Tem sido comprovado que através de processos fermentativos que utilizam

fungos, leveduras e bactérias, é possível a produção de inulinase em grande escala. No projeto, ainda em andamento, a análise das imagens de leveduras será realizada segundo o procedimento definido por O'Shea [41], descrito acima, e um software proprietário chamado *Scion Imagen for Windows* da *Scion Corporation*, para fazer a quantificação da morfologia.

O objetivo desta aplicação é efetuar uma segmentação de imagens de leveduras através da análise do espaço de escalas. A análise baseia-se no estudo de determinados parâmetros das células e da hierarquia que representa a imagem de levedura. Essa etapa de análise é descrita na Seção 5.4.2. Experimentos e diversos resultados de imagens segmentadas são mostrados na Seção 5.4.3. Comentários e discussões acerca dos resultados são realizados no final desta Seção.

5.4.2 Metodologia

A análise hierárquica é uma ferramenta importante especialmente quando a qualidade da segmentação depende da resolução da imagem. Trabalhos recentes usam representações e propriedades hierárquicas na segmentação de imagens médicas, além de atributos gerais, como por exemplo o apresentado por Metzler [35].

O algoritmo utilizado na segmentação de leveduras pode ser sumarizado em 3 passos:

1. *Criação do espaço de escalas* – Calcula-se a correspondente árvore dos lagos críticos para a imagem de levedura, conforme descrito no Capítulo 3.
2. *Cálculo de atributos* – Para todos os nós da árvore dos lagos críticos, calculam-se os atributos que serão utilizados na etapa de análise.
3. *Análise hierárquica* – Inicia-se a análise pelo critério do tempo de vida, que eliminará nós próximos às folhas da árvore dos lagos críticos. Em seguida, utiliza-se o critério de área para eliminar nós próximos à raiz da árvore dos lagos críticos. Finalmente, aplicam-se os outros critérios, como por exemplo nível médio de cinza, circularidade, volume etc.

Um critério que pode ser usado com sucesso na segmentação é o ajuste de modelos geométricos primitivos às células de leveduras. Um dos mais usados é a elipse, que se assemelha a alguns tipos de células classificadas

simplesmente de *leveduras* ou *leveduras alongadas* por O'Shea[41]. Neste trabalho, utiliza-se um critério de ajuste de elipse descrito por Fitzgibbon [27]. A técnica inicia minimizando a equação de ajuste:

$$E = \| \mathbf{D} \mathbf{a} \|^2 \quad (5.2)$$

onde $\mathbf{D}$ é chamada *matriz projeto* e $\mathbf{a}$ é a solução da equação geral da cônica, dada pela seguinte equação:

$$F(\mathbf{a}, \mathbf{x}) = \mathbf{a} \cdot \mathbf{x} = ax^2 + bxy + cy^2 + dx + ey + f = 0 \quad (5.3)$$

onde $\mathbf{a} = [a \ b \ c \ d \ e \ f]^T$ e $\mathbf{x} = [x^2 \ xy \ y^2 \ x \ y \ 1]^T$ representam a notação vetorial da equação.

Este problema fornece um auto-sistema e produz seis pares de auto-valores e auto-vetores como solução. Um teorema descrito em [27] prova que o sistema admite exatamente uma única solução, segundo certas restrições. Esta solução também é invariante à rotação e translação dos pontos que geram a elipse.

Outro critério relacionado ao ajuste de primitivas às células de leveduras é o *fator de forma*, que mede o grau de circularidade de uma região. O fator de forma é definido como sendo a relação entre a área e o volume de uma região. Para um círculo, essa relação é constante e igual a $R/2$, onde R é o seu raio.

5.4.3 Experimentos e Resultados

Os resultados apresentados foram obtidos em uma máquina Pentium III 1.1 GHz, com 256 MB de memória, rodando o sistema operacional Windows. Também foram utilizadas estações SUN Ultra 1, rodando SunOS com 64 MB de memória. As funções e *scripts* foram desenvolvidos em *MATLAB*, cuja versão instalada é a 6.0, utilizando-se de funcionalidades presentes na *toolbox* de Morfologia Matemática da *SDC Morphology*.

As imagens de leveduras foram cedidas pela FEA — Faculdade de Engenharia de Alimentos da Unicamp. As imagens foram capturadas diretamente de um microscópio eletrônico, fotografadas e escaneadas pelo doutorando Bernardo Yopez. Utilizou-se o formato de gravação JPEG, com dimensões da ordem de 1000×600. Para efeitos de eficiência de implementação e edição, as imagens de células de leveduras foram divididas em partes menores. Para imagens

de dimensões 256×256 , a imagem segmentada era obtida em aproximadamente 1min. Contudo, os resultados podem ser obtidos em tempo real caso se utilize a Linguagem C e os algoritmos sejam otimizados.

A Figura 5.6 apresenta um primeiro resultado da segmentação de imagens de leveduras do tipo *Kluyveromyces marxianus* utilizando a análise hierárquica do seu espaço de escalas. A imagem original é mostrada em (a) e um conjunto de imagens limiarizadas nos níveis de cinza 80, 100, 120, 150 e 170 são apresentadas nas Figuras 5.6(b)-(f), respectivamente. A limiarização é o procedimento inicialmente adotado em diversos trabalhos de segmentação de leveduras, como citado anteriormente, e essas figuras ilustram a dificuldade em identificar um limiar ótimo, a perda de contornos das células, o possível surgimento de novas células e a necessidade de maior processamento nas imagens a fim de segmentá-las corretamente. As Figuras 5.6(g),(h) mostram duas partições da imagem original, cujo número de regiões foi escolhido pelo usuário de acordo com a quantidade de células presentes na imagem. Essa metodologia vem sendo adotada em recentes trabalhos de segmentação hierárquica [17], [19], [20]. A dificuldade está exatamente na determinação da partição que melhor representa a segmentação da célula. A segmentação obtida através do método descrito em [39] é mostrada na Figura 5.6(i). Por fim, a Figura 5.6(j) apresenta a segmentação da imagem original através da análise do espaço de escalas obtido pela *ALC*. Neste resultado, utilizam-se os critérios tempo de vida, filtro de área mínima das células e o ajuste de elipse.

Uma rápida comparação das imagens presentes nas Figuras 5.6(i) e (j) pode levar a crer que ambas são idênticas (ao menos da célula ausente no canto superior esquerdo). Uma análise da área de cada objeto comprova que o método descrito por O'Shea [39],[41] implica em uma área cerca de 10% maior que no resultado gerado pela segmentação via análise do espaço de escalas. Esse valor maior de área é devido a não preservação dos contornos e, portanto, dimensões, das células. Foram gerados outros resultados na tentativa de incluir a célula ausente na segmentação via método descrito por O'Shea, mas isso não foi possível, devido ao surgimento de ruído produzido pela binarização. Esse problema já havia sido relatado pelo autor, que cita que em alguns casos é necessária intervenção humana para distinguir células de ruídos ou objetos que possam ser gerados no processo de binarização [39]. Uma análise das bordas das células também comprova que no caso da segmentação via análise do espaço de escalas, ao contrário da imagem na Figura 5.6(i), as bordas das células são mais regulares e respeitam os

contornos presentes na imagem do gradiente.

Na Figura 5.7 apresenta-se de forma didática a metodologia de análise do espaço de escalas, como apresentada na Seção 5.4.2. As Figuras 5.7(a) e (b) mostram uma imagem de células de levedura e seu dendrograma, respectivamente. Para efeitos de edição o dendrograma é simplificado no que diz respeito à quantidade de nós (para esta imagem, a *ALC* possui mais de 1000 nós). As Figuras 5.7(c)-(d) apresentam as imagens resultantes após cada etapa realizada: análise do tempo de vida das regiões, filtro de área e ajuste das regiões através de uma elipse, segundo o procedimento explicado. Na imagem final segmentada que é mostrada na Figura 5.7(e), são retiradas as regiões ou células que tocam as bordas da imagem.

A influência da variação do *tempo de vida* (*ST*) das regiões da *ALC* de uma imagem de levedura pode ser vista na Figura 5.8. A Figura 5.8(a) mostra a imagem original da célula de levedura e as Figuras 5.8(b)-(e) apresentam imagens cujos tempos de vida das regiões e classes são maiores que 430, 600, 710 e 1100, respectivamente. Observe a diminuição do número de regiões nas imagens a medida que *ST* aumenta. A Figura 5.8(a) e aquelas apresentadas nas Figuras 5.7(a) e 5.9(a) fazem parte de uma mesma imagem de levedura denominada *kluysvI6*.

As Figuras 5.9(b),(d) mostram outros dois resultados para as imagens de leveduras apresentadas em (a) e (c), respectivamente. Utilizaram-se somente os critérios tempo de vida ($ST > 200$) e área das células ($A > 80$). Todas as células que tocam as bordas da figura foram retiradas da imagem resultante do processo de segmentação. Este procedimento é normalmente adotado nas contagens de células realizadas em laboratório.

É feita também uma análise para uma outra classe de imagens de leveduras, apresentada na Figura 5.10. As mesmas células de leveduras mostradas nas imagens anteriores foram obtidas através de um diferente processo espectrofotométrico.

A segmentação de imagens de células de leveduras baseada na análise multiescala da árvore dos lagos críticos apresentou uma melhor qualidade nos resultados, quando comparados aos resultados obtidos com métodos tradicionais. Essa afirmação implica em 3 fatores: segmentação das várias células presentes na imagem, preservação dos contornos das células e, por conseguinte, manutenção das propriedades das regiões que correspondem às células (perímetro e área).

Os critérios de ajuste de elipse e do cálculo da circularidade das regiões se mostraram adequados a esta aplicação, mas não suficientes para a seg-

mentação das leveduras. Em leveduras do tipo *pseudohyphae* [41], que se assemelham à galhos de árvores bifurcados, certamente esses critérios não seriam válidos.

Outros resultados, comparações e discussões sobre a segmentação de células de leveduras através da análise do espaço de escalas gerado pela *ALC* podem ser vistos em Carvalho [43].




Figura 5.6: Resultados obtidos para imagens de leveduras: (a) imagem original; (b) imagem limiarizada com $T > 80$; (c) imagem limiarizada com $T > 100$; (d) imagem limiarizada com $T > 120$; (e) imagem limiarizada com $T > 150$; (f) imagem limiarizada com $T > 170$; (g) Partição com 12 regiões; (h) Partição com 30 regiões; (i) Imagem segmentada pelo método descrito em [39],[41], a partir da imagem binarizada (e); (j) Imagem segmentada via análise do espaço de escalas gerado pela *ALC*.




Figura 5.7: Sequência adotada na análise do espaço de escalas: (a) imagem original; (b) dendrograma simplificado de (a); (c) imagem resultante do critério ST ; (d) imagem resultante do critério área aplicado à imagem (c); (e) imagem final das células segmentadas, após utilização do critério de ajuste de elipse.




Figura 5.8: Variação do *tempo de vida* na segmentação de células de leveduras: (a) imagem original; (b) imagem com $ST > 430$; (c) imagem com $ST > 600$; (d) imagem com $ST > 710$; (e) imagem com $ST > 1100$; (f) imagem segmentada com critérios ST , área e ajuste de elipse.




Figura 5.9: (a),(c) Imagens originais de leveduras; (b),(d) células segmentadas.




Figura 5.10: (a) Imagem original de leveduras; (b) células segmentadas.

Capítulo 6

Conclusão

6.1 Contribuições desta tese

Neste trabalho, realizou-se uma análise da representação de imagens conhecida como árvore dos lagos críticos, que permitiu desenvolver as tarefas de segmentação e segmentação temporal, avaliação dos contornos das linhas de watershed e casamento de imagens. A análise, em sua maior parte, teve como base a exploração de propriedades de hierarquia presentes nesta estrutura, auxiliada pelo desenvolvimento de algoritmos em grafos. Optou-se em não fazer nenhum pré-processamento nas imagens trabalhadas, em função do caráter de atuação específica das técnicas de pré-processamento a grupos de imagens.

Como discutido em diversas partes desta tese, a segmentação de objetos através de análise hierárquica vem apresentando diversas contribuições à área, principalmente em função da semelhança de como o ser humano realiza essa mesma tarefa. As técnicas de segmentação hierárquica são importantes, por exemplo, na obtenção de VOP's (*video-object planes*) em algoritmos de segmentação de vídeo [86]. Além disso, houve um ganho em *riqueza* garantido pela possibilidade de se explorar o espaço de escalas gerado pela representação adotada. Neste sentido, no Capítulo 3 foi apresentado um método para se segmentar imagens através da escolha de um índice hierárquico e um único ponto sobre o objeto (seleção de regiões de interesse através de índice hierárquico). Juntamente com operações hierárquicas locais de re-segmentação e supressão, essa ferramenta é de grande valia na definição de objetos semânticos. Essa metodologia foi aplicada na segmentação espaço-

temporal de imagens de ressonância magnética, obtendo bons resultados, e gerando a publicação de dois trabalhos (*Spatiotemporal segmentation of MR image sequence based on hierarchical analysis* [61] e *Regions Tracking in Ventricle MR Sequence Based on Hierarchical Analysis* [60]). A segmentação de imagens via índice hierárquico demonstrou ser uma técnica viável para uso em imagens de diferentes classes, em termos de tempo de processamento e na obtenção de bons resultados. A vantagem reside na simplicidade e na redução da interação com o usuário, que dispensa o desenho do contorno de objetos. Em alguns casos pode-se necessitar de outro tipo de interação (uso de marcadores, por exemplo) para incluir ou retirar objetos na imagem resultante.

Ainda no Capítulo 3, tratou-se da avaliação dos contornos do watershed em níveis de cinza, dada pelo valor de extinção. A metodologia padrão é a construção de uma estrutura denominada de lista de inundação, proposta em 1996 por Najman e Schmitt [13]. Apresentaram-se duas outras formas de se realizar essa tarefa, via a análise da árvore geradora mínima e da árvore dos lagos críticos. É difícil comparar a eficiência computacional dessas metodologias sem a análise da complexidade dos algoritmos. Contudo, na comparação das operações que a lista de inundação e a ALC efetuam, verifica-se que a primeira pode vir a realizar busca de nós ancestrais em duas sub-árvores diferentes, contra somente uma no caso da ALC.

Em seguida, foi proposta uma metodologia de casamento de imagens baseada na construção de grafo associativo e determinação do clique máximo. O método apresentado tem vantagens sobre outros procedimentos, já que através da exploração da estrutura hierárquica da árvore dos lagos críticos pode-se tratar de erros de segmentação decorrentes do watershed. A idéia se torna interessante no momento em que se utilizam critérios que reduzem quantidades de nós e arestas. O critério do caminho orientado, antes utilizado em uma diferente estrutura hierárquica e para imagens binárias, mostra-se apropriado na tarefa de redução da densidade de arestas. Um primeiro trabalho foi apresentado no Sibgrapi de 2002 (*Hierarchical Regions Matching in Image Sequences Through Association Graph* [62]). Uma abordagem que merece mais estudos é a flexibilização do critério do caminho orientado, utilizado pela primeira vez nesta Tese. A flexibilização deste critério possibilita corresponder nós em diferentes níveis da estrutura e tratar de erros de segmentação. As dificuldades se apresentam no âmbito da complexidade do algoritmo de determinação do clique máximo, sendo necessário mais esforços para o aumento da sua eficiência computacional.

Por fim, a análise multiescala permitiu a segmentação de imagens de células de leveduras (tipo de fungo usado na indústria alimentícia). Na análise da estrutura hierárquica gerada pela ALC, diferentes parâmetros foram usados na discriminação das células. Foi dada ênfase ao ajuste de um modelo de elipse à forma da célula, além do parâmetro hierárquico conhecido como tempo de vida. Os resultados apresentados no Capítulo 5 se mostraram bastante promissores e produziram os trabalhos *Image segmentation by analysis of scale-space* [28] e *Segmentation of images of Yeast cells by Scale-space analysis* [43]. Foram realizadas algumas comparações com outros métodos, percebendo-se uma grande vantagem deste no que diz respeito à preservação dos contornos das células e, por conseguinte, das suas dimensões. Isso se refletiu no cálculo da área das células, de tal forma que o valor calculado pelo método proposto foi sempre menor do que o calculado por outros métodos presentes na literatura. A análise multiescala se mostra adequada para segmentar imagens que possuam regiões/objetos semânticos que possam ser discriminados com uma quantidade pequena de parâmetros. Caso contrário, estudos mais aprofundados sobre a influência de cada parâmetro se fazem necessários, além do uso de funções e/ou métricas que combinem o uso de tais parâmetros.

Os algoritmos implementados geraram mais de 50 funções em *MATLAB*. Procurou-se desenvolvê-las da forma mais genérica e abrangente possível, a fim de que possam ser aplicadas em problemas diferentes dos aqui apresentados. As funções escritas em código do *MATLAB*, assim como todo o material gerado neste trabalho (projetos, relatórios, artigos, etc) foram gravadas em um CD e estão disponíveis para o grupo de pesquisa em Processamento de Imagens do DCA.

6.2 Perspectivas

Há bastante trabalho a ser explorado nas linhas iniciadas nesta tese. Citam-se algumas a seguir, divididas por temas.

Casamento de imagens

- Usar o critério do caminho orientado como forma de medir a similaridade (ou dissimilaridade) entre duas ALCs. A flexibilização deste critério, permitindo correspondência entre nós em diferentes níveis, pode ser comparada a operações de edição ou criação de nós na árvore.

O diferencial desta proposição em relação a outros trabalhos na literatura ([63], por exemplo) está em que na ALC os atributos estão localizados nos nós, em contraste com a maioria dos trabalhos que adota pesos nas arestas. Desta forma, as características de cada região (que correspondem aos nós) puderam ser exploradas diretamente.

- A utilização da ALC completa para a tarefa de correspondência é bastante dispendiosa. Podem existir milhares de nós para uma imagem de tamanho 256×256 , por exemplo. A fim de reduzir a quantidade de nós a serem trabalhados e de focar a atenção nos objetos semânticos da aplicação de casamento em seqüências de imagens de ressonância magnética, a escolha da partição inicial apropriada foi efetuada através de conhecimento prévio da estrutura. Portanto, seria interessante determinar automaticamente uma *partição inicial ótima* das imagens a serem casadas.

Segmentação

- A fim de comparar diferentes estruturas hierárquicas, é interessante aplicar os mesmos critérios em outras representações como por exemplo a árvore dos componentes e a árvore de partição binária.
- Efetuar o agrupamento de regiões de outras formas (isso pode implicar em que o algoritmo não seja classificado como watershed). Como discutido no texto, a ALC corresponde a um agrupamento do tipo Ligação Simples.
- Utilizar descritores de textura das regiões da imagem na análise da estrutura hierárquica (também pode ser utilizado como atributo no processo de casamento de imagens).

Segmentação espaço-temporal

- As principais características usadas na aplicação de segmentação do volume de sangue do ventrículo esquerdo basearam-se no nível de cinza e na área (o índice hierárquico foi usado na ordem de uso das operações de supressão e re-segmentação). Uma idéia é usar diferentes características (valor de extinção, ajuste de forma), já que o nível de cinza, principalmente, pode sofrer grandes variações.

- Também, pretende-se usar um procedimento similar em outros tipos de seqüências de imagens, como por exemplo, video-conferência. O principal intuito é reduzir a necessidade de indicar contornos em etapas iniciais (uso da operação de escolha da região de interesse via índice hierárquico) e efetuar a perseguição do objeto baseada nas operações hierárquicas locais.

Avaliação dos contornos do watershed

- O principal ponto a ser resolvido é o problema de conectividade encontrado após a operação de limiarização. Esse problema gera regiões não fechadas. Este problema envolve a detecção e localização dos contornos das imagens, tratando-se de um problema topológico e envolve questões de geometria discreta [45].
- Outra sugestão de trabalho futuro é a realização de uma comparação da complexidade computacional entre os algoritmos apresentados.

Uma última sugestão é pesquisar o uso da ALC na indexação de imagens, ou seja, em processos de armazenamento e recuperação de conteúdo em base de dados. Esta foi uma das idéias iniciais da tese e um primeiro estudo já foi efetuado no trabalho *Indexação e casamento hierárquico de imagens* [85].

Referências Bibliográficas

- [1] R. A. Lotufo, W. D. Silva. Minimal set of Markers for the watershed transform. In: Proceedings of International Symposium on Mathematical Morphology, Sydney/Austrália, abril, 2002.
- [2] R. A. Lotufo, A. Falcão, F. Zampiroli. IFT-Watershed from gray-scale marker. Proc. of XV Brazilian Symposium on Computer Graphics and Image Processing, Brasil, p. 146-152, outubro, 2002.
- [3] F. Meyer. The dynamics of minima and contours. In: P. Maragos, R. W. Schafer and M. A. Butt, editors, Mathematical Morphology and its Applications to Image and Signal Processing, Kluwer Academic Publishers, pp. 329-336, 1996.
- [4] F. Meyer, P. Maragos. Multiscale Morphological Segmentations based on Watershed, Flooding and Eikonal PDE. Scale-Space, pp. 1-12, 1999.
- [5] F. Meyer. Hierarchies of partitions and morphological segmentation. In: Proc. of Scale-Space 2001, Canadá, pp. 161-182, julho, 2001.
- [6] S. Beucher, F. Meyer. The Morphological Approach to segmentation: The Watershed Transformation. In: Mathematical Morphology in Image Processing, chap. 12, E.R. Dougherty, editor, pp. 433-481, Marcel Dekker, New York, 1993.
- [7] R. Castagno, T. Ebrahimi, M. Kunt. Video Segmentation Based on Multiple Features for Interactive Multimedia Applications. IEEE Transactions on Circuits and Systems for Video Technology, vol. 8, no. 5, pp. 562-571, 1998.
- [8] F. Zanoguera, B. Marcotegui, F. Meyer. A toolbox for interactive segmentation based on nested partitions. In: Proceedings of the IEEE

- International Conference on Image Processing, vol. 1, pp. 21-25, Kobe/Japão, outubro, 2001.
- [9] F. Meyer. Topographic distance and watershed lines. *Signal Processing*, vol. 38, pp. 113-125, 1994.
 - [10] J. B. T. M. Roerdink, A. Meijster. The Watershed transform: definitions, algorithms and parallelization strategies, *Fundamenta Informaticae*, no. 41, pp. 187-228, 2000.
 - [11] P. Salembier. Unsupervised morphological segmentation for images. *IEEE Winter Workshop on Nonlinear Digital Signal Processing*, pp. 6.1—2.1-6.1—2.6, 1993.
 - [12] S. Beucher. Watershed, hierarchical segmentation and waterfall algorithm. In: J. Serra e P. Soile, editores, *Mathematical Morphology and its applications to image and signal processing*, pp. 69-76, Kluwer Academic Publishers, 1994.
 - [13] L. Najman, M. Schmitt. Geodesic Saliency of watershed contours and hierarchical segmentation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 18, no. 12, pp. 1163-1173, dezembro, 1996.
 - [14] C. Lemarechal, R. Fjørtoft. Comments on: Geodesic Saliency of watershed contours and hierarchical segmentation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 20, no. 7, pp. 764-766, julho, 1998.
 - [15] M. Schmitt. Response to the comments on: Geodesic Saliency of watershed contours and hierarchical segmentation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 20, no. 7, pp. 764-766, julho, 1998.
 - [16] M. Grimaud. La géodésie numérique en morphologie mathématique. Application à la détection automatique de microcalcifications en mammographie numérique, Tese de doutorado, Centre de Morphologie Mathématique, École de Mines de Paris, França, 1991.
 - [17] F. Zanoguera. Segmentation interactive d'images fixes et de séquences de video basée sur des hierarchies de partitions, Tese de doutorado, Centre de Morphologie Mathématique, École de Mines de Paris, França, 2001.

- [18] C. Vachier. Extraction de caractéristiques, segmentation d'image et morphologie mathématique. Tese de doutorado, Centre de Morphologie Mathématique, École de Mines de Paris, França, 1995.
- [19] W. D. Silva. Marcadores Mínimos usando Watershed. Tese de doutorado, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, 2001.
- [20] C. Gomila. Mise en correspondance de partitions en vue du suivi d'objets. Tese de doutorado, Centre de Morphologie Mathématique, École de Mines de Paris, França, 2001.
- [21] J. M. Rondina. Segmentação interativa do ventrículo esquerdo em seqüências de imagens de ressonância magnética (Cine MR). Tese de mestrado, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, 2001.
- [22] M. V. Agnus. Segmentation spatio-temporelle de séquences d'images par des opérateurs de morphologie mathématique. Tese de doutorado, Université Louis Pasteur de Strasbourg, França, 2001.
- [23] G. Matheron, J. Serra. The birth of mathematical morphology. In: Proc. of International Symposium on Mathematical Morphology 2002, pp. 1-16, Austrália, abril, 2002.
- [24] R. M. Haralick, S. R. Sternberg, X. Zhuang. Image Analysis Using Mathematical Morphology. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol 9, no. 4, julho, 1987.
- [25] E. Dougherty. An Introduction to Morphological Image Processing. SPIE, Optical Engineering Press, 1992.
- [26] J. Facon. Morfologia Matemática: teoria e exemplos. Editora da PUC-PR, 1996.
- [27] A. W. Fitzgibbon, M. Pilu, R. B. Fisher. Direct least squares fitting of ellipses, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 21, no. 5, maio, 1999.
- [28] M. A. G. Carvalho, R. A. Lotufo, M. Couprie. Image segmentation by analysis of scale-space. Proc. of XV Brazilian Symposium on Computer Graphics and Image Processing, p. 403, Brasil, outubro, 2002.

- [29] T. Lindeberg. Scale-space theory: a basic tool for analysing structures at different scales. *Journal of Applied Statistics*, vol. 21, no. 2, pp. 225-270, 1994.
- [30] U. Kothe. Local appropriate scale in morphological scale-space. *Proc. of 4th European Conference on Computer Vision*, vol.1, pp.219-228, 1996.
- [31] P. A. Morettin. *Ondas e Ondaletas*. Editora da USP, São Paulo, 1999.
- [32] F. Meyer, P. Maragos. Morphological scale-space representation with levellings. In: M. Nielsen, P. Johansen, O. F. Olsen, and J. Weickert (Eds.), *Scale-Space 99: Scale-Space Theory in Computer Vision*, pp. 187-198, 1999.
- [33] C. Vachier. Morphological scale-space analysis and feature extraction. *Proc. of International Conference on Image Processing*, vol. 3, pp. 676-679, 2001.
- [34] P. T. Jackway, M. Deriche. Scale-space properties of the multiscale morphological dilation-erosion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 18, no. 1, pp. 38-51, janeiro, 1996.
- [35] V. Metzler, T. Aach, C. Thies. Object-oriented Image Analysis by Evaluating the Causal Object Hierarchy of a Partitioned Reconstructive Scale-Space. In: *Proc. of ISMM2002*, pp. 265-276, Australia, April 2002.
- [36] M. Pelczar, R. Reid, E. C. S. Chan. *Microbiologia - Vol. 1*. McGraw-Hill, 1980.
- [37] M. Vitolo, P. S. Minami. *Leveduras em Biotecnologia*, 1989.
- [38] M. N. Pons, H. Vivier, J. F. Rémy, J. A. Dodds. Morphological characterization of yeast by image analysis. *Biotechnology and Bioengineering*, vol. 42, pp. 1352-1359, 1993.
- [39] D. G. O'Shea, P. K. Walsh. Morphological Characterization of the Dimorphic Yeast *Kluyveromyces marxianus* var. *marxianus* NRRLy2415 by Semi-Automated Image Analysis. *Biotechnology and Bioengineering*, vol. 51, pp. 679-690, 1996.

- [40] K. Zalewski, R. Buchholz. Morphological Analysis of Yeast Cells using an Automated Image Processing System. *Journal of Biotechnology*, vol. 48, pp. 43-49, 1996.
- [41] D. G. O'Shea, P. K. Walsh. The effect of culture conditions on the morphology of the dimorphic yeast *Kluyveromyces marxianus* var. *marxianus* NRRLy2415: a study incorporating image analysis, *Applied Microbiology and Biotechnology*, vol. 53, pp.316-322, 2000.
- [42] B. O. Y. Silva-Santisteban. Estudo de parâmetros de engenharia de processo que afetam a fisiologia e a produção de inulinase por *Kluyveromyces marxianus* VAR. *bulgaricus*. Projeto de Tese de doutorado, FEA – Unicamp, 2001.
- [43] M. A. G. Carvalho, R. A. Lotufo, M. Couprie. Segmentation of images of Yeast cells by Scale-space analysis. *Proc. of XVI Brazilian Symposium on Computer Graphics and Image Processing — SIBGRAPI 2003*, p. 376-380, São Carlos/SP, 2003.
- [44] M. Couprie, G. Bertrand. Topological Grayscale Watershed Transform. *Proceedings of VI SPIE Vision Geometry*, vol. 3168, pp. 136-146, 1997.
- [45] L. Najman, R. Vaillant. Topological and geometrical corners by watershed. *Proceedings of CAIP*, Hlavác e Sára, eds., LNCS 970, Springer-Verlag, 1995.
- [46] P. Hanusse, P. Guillaud. Semantique des images par analyse dendronique. *Anais do 8o. Congresso AFCET*, Lyon-Villeurbanne, França, pp. 577-598, 1991.
- [47] R. Jones. Attribute signatures for connected filtering and segmentation. In: R. Chaplin and W. Page (eds.), *Digital Image and Vision Computing: Techniques and Applications*, pp. 413-418, 1997.
- [48] J. Mattes, J. Demongeot. Efficient Algorithms to Implement Confinement Tree. *Proceedings of 9th Discrete Geometry for Computer Imagery (DGCI)*, Suécia, pp. 392-405, 2000.
- [49] L. Garrido, P. Salembier, J. R. Casas. Representing and retrieving regions using binary partition trees. *Proc. of International Conference on Image Processing - ICIP*, vol. 2, pp. 605-609, 1999.

- [50] P. Salembier, L. Garrido. Binary partition tree as an efficient representation for image processing, segmentation and information retrieval. *IEEE Trans. on Image Processing*, vol. 09, no. 04, pp. 561-576, abril, 2000.
- [51] L. Garrido, F. Marqués, M. Pardàs, P. Salembier, V. Vilaplana. A hierarchical technique for image sequence analysis. In: *Workshop on Image Analysis for Multimedia Application Services (WIAMIS)*, pp. 13-20, Louvain-la-Neuve, Belgium, junho, 1997.
- [52] P. Salembier. Overview of the MPEG-7 standard and of future challenges for visual information analysis. *EURASIP Journal on Applied Signal Processing*, Volume 4, pp. 1-11, abril, 2002.
- [53] P. Salembier, F. Marqués. Region-based representations of image and video: segmentation tools for multimedia services. *IEEE Trans. on Circuits and Systems for video Technology*, vol. 9, no. 8, pp. 1147-1169, dezembro, 1999.
- [54] P. Salembier, J. Llach, L. Garrido. Visual segment tree for MPEG-7 description schemes. *Pattern Recognition*, vol. 35, pp. 563-579, 2002.
- [55] Z. Wu, R. Leahy. An optimal graph theoretic approach to data clustering: theory and its application to image segmentation. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 15, no. 11, pp. 1101-1113, novembro, 1993.
- [56] M. Roux. *Algorithmes de Classification*. Masson, Paris, 1985.
- [57] J. P. Benzécri. *L'analyse de données. Tome I: La taxinomie*. Dunod, Bélgica, 1973.
- [58] B. V. Cutsem, B. Yeart. Indexed Dendrograms on Random Dissimilarities. *Journal of Classification*, vol. 15, pp. 93-127, 1998.
- [59] F. J. V. Zuben, L. C. Duarte, G. Stangenhäus, L. M. Pessôa, S. F. dos Reis. Bootstrap confidence regions for canonical variates: Application to studies of evolutionary differentiation, *Biometrical Journal*, vol. 40, no. 3, pp. 327-339, 1998.

- [60] M. A. G. Carvalho, R. A. Lotufo, M. Couprie. Regions tracking in ventricle MR sequence based on hierarchical analysis. Proc. of XV Brazilian Symposium on Computer Graphics and Image processing, Brasil, p. 410, outubro, 2002.
- [61] M. A. G. Carvalho, R. A. Lotufo, M. Couprie. Spatiotemporal segmentation of MR image Sequence based on Hierarchical Analysis. Proc. of Seventh International Symposium on Signal Processing and its Applications — ISSPA 2003, Paris/FR, p. 677-680, julho, 2003.
- [62] M. A. G. Carvalho, R. A. Lotufo. Hierarchical Regions Matching in Image Sequences Through Association Graph. Proc. of XIV Brazilian Symposium on Computer Graphics and Image processing, Brasil, p. 396, outubro, 2001.
- [63] J. Mattes, R. Mathieu, J. Demongeot. Tree representation for image matching and object recognition. 8th International conference on DGCI, France, pp 289-309, março, 1999.
- [64] S. Gold, A. Rangarajan. A Graduated Assignment Algorithm for Graph Matching. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 18, no. 4, pp. 377-388, abril, 1996.
- [65] J. T.Wang, K. Zhang, K. Jeong, D. Shasha. A system for approximate tree matching. IEEE Transactions on Knowledge and Data Engineering, vol. 6, no. 4, pp. 559-571, 1994.
- [66] H. Bunke, K. Shearer. A graph distance metric based on the maximal common subgraph. Pattern Recognition Letters, vol. 19, pp. 255-259, 1998.
- [67] K. Siddiqi, A. Shokoufandeh, S. J. Dickinson, S. W. Zucker. Shock Graphs and Shape Matching. International Journal of Computer Vision, no. 30, pp. 1-22, 1999.
- [68] M. Sonka, V. Hlavac, R. Boyle. Image Processing, Analysis and Machine Vision. Brooks/Cole Publishing Company, 1999.
- [69] F. V. Heijden. Image Based Measurement Systems - Object Recognition and Parameter Estimation. John Wiley & Sons, 1994.

- [70] M. Pelillo, K. Siddiqi, S. W. Zucker. Matching Hierarchical Structures Using Association Graphs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 21, no. 11, pp. 1105-1119, novembro, 1999.
- [71] M. Pelillo, K. Siddiqi, S. W. Zucker. Attributed tree matching and maximum weight cliques. *Proc. of 10th International Conference on Image Analysis and Processing*, Itália, pp. 1154-1159, setembro, 1999.
- [72] I. M. Bomze, M. Budinich, P. M. Pardalos, M. Pelillo. The Maximum Clique Problem - Handbook of Combinatorial optimization. Kluwer Academic Publishers, 1999.
- [73] P. M. Pardalos. An Algorithm for Finding the Maximum Clique on an Arbitrary Graph. In <http://www.mai.liu.se/~nigol/MAXCLIQUE>.
- [74] E. Balas, C. S. Yu. Finding a maximum clique in a arbitrary graph, *SIAM Journal Comp.*, vol. 15, no. 4, pp. 1054-1068, novembro, 1986.
- [75] A. Branca, E. Stella, A. Distanti. Feature matching by searching maximum clique on high order association graph, *Proc. of 10th International Conference on Image Analysis and Processing*, Itália, setembro, 1999.
- [76] F. Pla, J. A. Marchant. Matching features points in image sequences through a region-based method, *Computer Vision and Image Understanding*, vol. 66, no. 3, pp. 271-285, 1997.
- [77] B. Yang, W. E. Snyder, G. L. Bilbro. Matching oversegmented 3D images to models using association graphs, *Image and Vision Computing*, vol. 7, no. 2, pp. 135-143, 1989.
- [78] A. López, F. Pla. Dealing with segmentation errors in region-based stereo matching, *Pattern Recognition*, no. 33, pp. 1325-1338, 2000.
- [79] L. J. Chipman, H. S. Hanganath. A fuzzy relaxation algorithm for matching imperfectly segmented image to models. *Proceedings of Southeastcon*, vol. 1, p. 128-136, abril, 1992.
- [80] A. Perchant, I. Bloch. Graph fuzzy homomorphism interpreted as fuzzy association graphs. *Proceedings of 15th Int. Conf. on Pattern Recognition*, vol.2, p. 1042-1045, Espanha, setembro, 2000.

- [81] R. Johnsonbaugh. Discrete Mathematics. Macmillan Publishing Company, 1993.
- [82] M. Gondran, M., Minoux. Graphes et Algorithmes. Collection de la Direction des Études et Recherche d'Électricité de France/FR, Ed. Eyrolles, 1995.
- [83] C. Lee, A. Joshi. Correspondence problem in image sequences analysis, Pattern Recognition, vol. 26, no. 1, pp. 47-61, 1993.
- [84] U. Manber. Introduction to Algorithms — A creative approach, Addison-Wesley, 1989.
- [85] M. A. G. Carvalho, R. A. Lotufo. Indexação e casamento hierárquico de imagens. IV Semana de Informática, Universidade Potiguar, Natal/RN, 2000.
- [86] T. Meier, K. N. Ngan. Automatic Segmentation of Moving Objects for Video Object Plane Generation. IEEE Transactions on Circuits and Systems for Video Technology, vol. 8, nº 5, setembro, 1998.