

Universidade Estadual de Campinas
Faculdade de Engenharia Elétrica e de Computação
Departamento de Engenharia Biomédica

Representação em múltiplas escalas para identificação automática de estruturas em imagens médicas

Autora: Marina de Fátima de Sá Rebelo

Orientador: Prof. Dr. Lincoln de Assis Moura Jr.

Co-orientador: Prof. Dr. Sérgio Shiguemi Furuie

Co-orientador: Prof. Dr. Eduardo Tavares Costa

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 Biomédica.**

Campinas, SP
Outubro/2005

Universidade Estadual de Campinas
Faculdade de Engenharia Elétrica e de Computação
Departamento de Engenharia Biomédica

Representação em múltiplas escalas para identificação automática de estruturas em imagens médicas

Autora: Marina de Fátima de Sá Rebelo

Orientador: Prof. Dr. Lincoln de Assis Moura Jr.

Co-orientador: Prof. Dr. Sérgio Shiguemi Furuie

Co-orientador: Prof. Dr. Eduardo Tavares Costa

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 Biomédica.**

Banca Examinadora

Prof. Dr. Lincoln de Assis Moura Jr.....FUNDAÇÃO ATECH/VIDATIS
Prof. Dr. Marco Antonio Gutierrez.....INCOR/USP
Prof. Dr. Nelson Delfino d'Ávila Mascarenhas.....DC/UFSCAR
Prof. Dr. Roberto de Alencar LotufoDEC/FEEC/UNICAMP
Prof. Dr. Sérgio Santos Muhlen.....DEB/FEEC/UNICAMP
Profa. Dra. Vera Lúcia da Silveira Nantes Button.....DEB/FEEC/UNICAMP

Campinas, SP
Outubro/2005



Blossoming Almond Tree Branches
Vincent Van Gogh

O conceito do galho de árvore faz sentido apenas em escalas de alguns centímetros a, no máximo, uns poucos metros.

Não faz nenhum sentido discutir o conceito de galho no nível de nanometro ou quilômetro.



Cardboard Molecule
Tom Moody

Nessas escalas é mais relevante falar a respeito das moléculas que formam a árvore

*... e da floresta
na qual a árvore cresce*

Jan Koenderink
"The structure of images", 1984



Forestlight
David Lauder

Resumo

Rebelo, M.F.S. *Representação em múltiplas escalas para identificação automática de estruturas em imagens médicas*. 2005, 203p. Tese (Doutorado) – Faculdade de Engenharia Elétrica e de Computação, Universidade de Campinas, Campinas, 2005.

A identificação de estruturas constitui uma etapa importante em processamento de imagens médicas. Este trabalho pretende contribuir na área de identificação de imagens médicas, e tem por objetivo propor uma metodologia genérica para identificação de estruturas, utilizando uma abordagem em múltiplas resoluções, o espaço de escalas. Avalia-se a utilização de uma representação de dados em múltiplas escalas que permite a inclusão de conhecimento *a priori* sobre as estruturas em diversas escalas e ainda explora-se a idéia de realizar o processamento em uma escala apropriada. A metodologia é composta das seguintes etapas: (i) criação de uma representação dos dados em diversas escalas utilizando a teoria de espaço de escalas linear. (ii) A seguir, analisa-se as imagens presentes em todas as escalas e detecta-se as características relevantes das imagens. O produto dessa etapa é uma representação em forma de árvore que mapeia as relações entre as estruturas no espaço de escalas. Essa representação serve como base para o passo seguinte, o processamento de alto nível, no qual o conhecimento *a priori* sobre a estrutura procurada é modelado e incluído na representação. (iii) A última etapa é o casamento entre os elementos presentes na estrutura construída e um padrão conhecido que descreve a estrutura de interesse. A metodologia é genérica e o tipo de informação armazenada no padrão depende da aplicação específica. Neste trabalho, foi implementado um protótipo, no qual são utilizadas informações geométricas para identificação de órgãos em imagens 2D de *phantom* que reproduz a anatomia humana. Os resultados da aplicação da metodologia em imagens com diferentes níveis de ruído e contraste foram bastante satisfatórios. As duas primeiras etapas já estão implementadas para imagens 3D e novos parâmetros podem ser facilmente incluídos na etapa de casamento para aplicações em imagens tri-dimensionais.

Palavras-Chave: Processamento de imagens, identificação de estruturas, representação, espaço de escalas.

Abstract

Rebelo, M.F.S. *Multiscale representation for automatic identification of structures in medical images*. 2005, 203p. Thesis (Doctoral) – Faculdade de Engenharia Elétrica e de Computação, Universidade de Campinas, Campinas, 2005.

The identification of structures is an important step for several applications in the field of medical imaging. The purpose of this thesis is to contribute to the field of identification in medical images. Its main goal is to propose a generic methodology for identification of structures by using a multiresolution approach, the scale-space. We evaluate the use of a data representation that allows the inclusion of *a priori* knowledge about the structures in several scales and we also develop the idea of an appropriate scale to perform the processing. The proposed methodology comprises the following steps: *(i)* creation of an image representation in several scales using the scale space theory. *(ii)* Then the images in all scales are inspected and relevant features are extracted; the output of this step is a tree structure that maps the relations of the detected features throughout the scale space; the representation serves as a guide to subsequent high level processing step, where *a priori* knowledge about the desired feature is modeled and included in the representation. *(iii)* The last step is the matching between the elements present in the built structure and a known pattern that describes the structure of interest. The proposed methodology is generic and the type of information to be used depends strongly on the application. In this Thesis, we built a prototype application in which we used geometric information for identification of organs in 2D phantom images that reproduces human anatomy. The results of applying this method to a set of images with different noise and contrast levels were quite satisfactory. The two initial steps of the method were also implemented for 3D images. New parameters can be easily included in the matching step for extension to 3D.

Keywords: Image processing, identification of structures, representation, scale space.

*Pensava que tudo sabia...
Hoje sei que continuo no aprendizado da vida.
Sempre seguindo seus passos,
Há saudade!
Que saudade de meu velho e querido pai,
Com seus braços fortes a me proteger,
Com a sua fala a me acalmar.
Com o seu amor a me dar segurança.*

....

*Para quem não o conheceu saiba, este é meu velho e
querido pai.*

Texto adaptado de: Sócrates Tussato

A Alberto, meu pai

Agradecimentos

Aos professores Sérgio Shiguemi Furuie e Lincoln de Assis Moura Jr., amigos queridos e orientadores, não apenas deste trabalho de pesquisa. De formas totalmente distintas (talvez complementares?), ambos iniciaram e guiaram meus passos como profissional nas áreas de Engenharia Biomédica e Informática em Saúde. Ao longo de todos esses anos de convivência e trabalhos conjuntos, sempre representaram exemplos de conduta profissional a ser seguida.

Ao professor Eduardo Tavares Costa, pela sua incansável determinação em fazer com que este trabalho fosse concluído. Seu auxílio na etapa final foi muito importante.

Ao Marco Antonio Gutierrez, por todo o apoio recebido durante a execução deste trabalho. Sua participação foi fundamental em sua primeira fase, quando construímos juntos a biblioteca de funções de espaço de escalas. Muitas discussões interessantes e trabalhos surgiram e continuam surgindo dessa parceria.

Ao Ramon Alfredo Moreno, meu grilo falante. Em muitos momentos nos quais a finalização deste trabalho parecia algo inatingível, suas palavras incutiram a vontade de continuar. Seu auxílio na implementação das rotinas em Java foi também muito valioso, assim como o foram suas sugestões, idéias e enorme apoio na última fase do trabalho.

À Cecil Chow Robilotta, minha primeira Mestre na carreira de pesquisadora e com quem aprendi a pensar e elaborar um trabalho científico. Seu auxílio na revisão, suas sugestões e discussões muito enriqueceram este trabalho.

Ao inesquecível Cândido Pinto de Melo, outro Mestre de minha vida profissional, e que foi o responsável pelo meu ingresso nas áreas de Engenharia Biomédica e de Informática em Saúde. Tive ainda o privilégio raro de tê-lo como meu colega de turma nas disciplinas de pós-graduação da Unicamp.

Ao Umberto Tachinardi, por todo o apoio e amizade. Suas indagações e ponderações, sempre inteligentes, são um estímulo contínuo para que continuemos a ser eternos questionadores e buscadores.

Ao Nivaldo Bertozzo, pelo apoio e estímulo ao desenvolvimento deste trabalho, desde nosso período como colegas de turma nas disciplinas de pós-graduação. Ao Marcelo Santos, pela amizade e auxílio na implementação da rotinas de espaço de escala não lineares. Ambos “carregaram o piano” da Unidade de P&D durante o período final de elaboração da tese. Muito obrigada aos dois pela compreensão.

À Giuliana Orlandi e Marcos Yamaguti, antes de tudo amigos do coração, que sempre torceram pela finalização deste trabalho. Sem o seu auxílio na infraestrutura, minha tarefa nos servidores Sun e Xeon certamente teria sido muito mais árdua.

Aos amigos da Unidade de P&D, pesquisadores e estudantes, atuais ou que passaram por aqui e já se foram, que ajudam a fazer de nossa unidade um local de trabalho muito agradável, propício à discussão de novas idéias e à criação. Em especial gostaria de agradecer a alguns deles: Fabiane Nardon, Luiz Parzianello, Gustavo Motta, Luis Kobayashi, Júlio Figueiredo, Paulo Pilon e Wietske Meyering.

À Silvia Araújo e Lúcia Queiroz, secretárias do Serviço de Informática InCor, sempre dispostas a ajudar na solução de nossos problemas.

Ao Serviço de Informática InCor, na figura de todos os seus funcionários. Apesar de todo o estresse e correria, que caracterizam um serviço que precisa funcionar em regime 24 por 7, existe o espaço e o reconhecimento da importância da realização de tarefas de pesquisa, em meio a tantas atribulações dos trabalhos de rotina. Aqui, mais uma vez, vai minha homenagem ao Cândido, que iniciou toda esta história, e também àqueles que o sucederam e que mantêm o espírito que caracteriza este Serviço desde o seu início: Umberto, Marco, Sérgio e Fábio.

Aos professores do Departamento de Engenharia Biomédica da Unicamp, por compartilharem todo o seu conhecimento.

Às secretárias da Pós Graduação da Faculdade de Engenharia Elétrica e de Computação da Unicamp, por todas as informações e auxílio prestados.

Aos pesquisadores do Image Science Institute do University Medical Center Utrecht. Em particular ao Professor Max A. Viergever, que viabilizou o período como pesquisadora visitante no grupo e aos Dr. Koen Vincken e Dr. Wiro Niessen, responsáveis pelo meu contato inicial com a teoria de espaço de escalas.

Ao Dr. Benjamin M.W. Tsui e seu grupo do Department of Biomedical Engineering, University of North Carolina (Chapel Hill), por gentilmente ceder o *phantom* 3D MCAT, utilizado nos experimentos do trabalho.

Ao CNPq pelo auxílio financeiro e recursos em equipamentos e à FAPESP pelo suporte em infra-estrutura de pesquisa.

A todos os meus amigos que, sem participar diretamente da elaboração do trabalho, deram suporte emocional e apoio para que ele fosse concluído. Em particular, gostaria de agradecer a algumas dessas pessoas, que ao longo desses anos sempre me incentivaram vivamente: Agda, Carlos, Cassiano, Cláudia, Mônica, Renata, Simon e Teresa. Deste grupo também fazem parte Henrique, meu irmão, e meus sobrinhos queridos Daniel, Rafael e Matheus.

Por fim, gostaria de agradecer a uma pessoa muito especial, Isabel, minha mãe, que sempre me incentivou a continuar meu aprimoramento profissional e que também sempre vibrou muito com minhas conquistas.

Sumário

LISTA DE FIGURAS	xv
LISTA DE TABELAS	xxiii
LISTA DE SÍMBOLOS	xxv
GLOSSÁRIO	xxvii
TRABALHOS PUBLICADOS	xxix
CAPÍTULO 1	1
INTRODUÇÃO	1
1.1. O PROBLEMA DA IDENTIFICAÇÃO AUTOMÁTICA	3
1.2. IDENTIFICAÇÃO EM IMAGENS MÉDICAS	3
1.3. BREVE INTRODUÇÃO À QUESTÃO DA ESCALA EM IMAGENS	4
1.4. NÍVEIS DE PROCESSAMENTO	6
1.5. OBJETIVO E ESTRUTURA DO TRABALHO	7
CAPÍTULO 2	11
IDENTIFICAÇÃO DE ESTRUTURAS	11
2.1. IDENTIFICAÇÃO DE ESTRUTURAS EM IMAGENS DIGITAIS	11
2.1.1. Colocação do problema	11
2.1.2. Identificação automática	15
2.1.3. Níveis de representação de dados	17
2.2. APLICAÇÕES MÉDICAS	23
2.2.1. Utilização de informações a priori para identificação de estruturas em processamento de imagens médicas	25
2.2.2. Identificação de estruturas aplicada a imagens médicas	26
2.2.3. Algumas aplicações	28
2.2.4. Utilização de abordagens em múltiplas escalas para identificação	31
CAPÍTULO 3	33
ESPAÇO DE ESCALAS	33
3.1. CONCEITOS GERAIS SOBRE A ABORDAGEM UTILIZANDO MÚLTIPLAS ESCALAS	33
3.2. O ESPAÇO DE ESCALAS LINEAR	36
3.2.1. Espaço de escalas	36
3.2.2. Teoria	38
3.2.3. Derivadas numéricas utilizando espaço de escalas	41
3.2.4. Operadores diferenciais utilizando espaço de escalas	43
3.2.5. Invariantes geométricos nas escalas como descritores da geometria da imagem	44
3.2.6. Limitações do espaço de escalas linear	45
3.3. O EMBASAMENTO FÍSICO PARA O PROCESSO DE DIFUSÃO	46
3.4. ESPAÇOS DE ESCALA NÃO LINEARES	47

3.4.1.	Difusão com condutância variável	48
3.4.2.	Outras abordagens	50
3.5.	SELEÇÃO DE ESCALAS	50
3.5.1.	Conceito de escalas apropriadas	50
3.5.2.	Métodos para seleção de escalas	52
3.6.	IMPLEMENTAÇÃO	53
3.6.1.	Criação das imagens de espaço de escalas	53
3.6.2.	Obtenção dos diferenciais nas escalas	54
3.6.3.	Linguagem de programação e ferramentas de desenvolvimento	54
3.7.	RESULTADOS	55
3.8.	DETECÇÃO DE ESTRUTURAS E REPRESENTAÇÃO	59

CAPÍTULO 4 **61**

DETECÇÃO DE ESTRUTURAS E REPRESENTAÇÃO EM MÚLTIPLAS ESCALAS	61	
4.1.	OPERADORES PARA DETECÇÃO DE CARACTERÍSTICAS DE IMAGEM	62
4.1.1.	Introdução	62
4.1.2.	Blobs de nível de cinza	63
4.1.3.	Definição	65
4.1.4.	Propriedades	67
4.1.5.	Motivação para uma hierarquia em múltiplas escalas	67
4.1.6.	Blobs de espaço de escalas	68
4.2.	A REPRESENTAÇÃO DE <i>PRIMAL SKETCH</i>	71
4.2.1.	<i>Primal Sketch</i>	71
4.2.2.	<i>Scale Space Primal Sketch</i> ou árvore de bifurcação	71
4.2.3.	Medidas de relevância dos SSBlobs	73
4.2.4.	Extração de estruturas importantes da imagem	74
4.2.5.	Considerações sobre a utilização do SSPS	74
4.2.6.	Considerações sobre a utilização do SSPS neste trabalho	75
4.3.	IMPLEMENTAÇÃO	76
4.3.1.	Operadores utilizados para detecção de blobs	76
4.3.2.	Linguagem de programação e ferramentas de desenvolvimento	78
4.3.3.	Estruturas de dados	79
4.4.	RESULTADOS	81
4.4.1.	Tempos de processamento	81
4.4.2.	Imagem 3D	82
4.4.3.	Imagem 2D de ressonância magnética	84
4.5.	INCLUSÃO DE INFORMAÇÃO A PRIORI NO SSPS	86

CAPÍTULO 5 **87**

INSERÇÃO DE INFORMAÇÕES A PRIORI NO SSPS	87	
5.1.	INCLUSÃO DE INFORMAÇÃO A PRIORI NO FORMALISMO DE SSPS	87
5.1.1.	Representação em árvore no SSPS	89
5.2.	APLICAÇÃO PILOTO	95
5.2.1.	Eliminação de nós na árvore de SSBlobs utilizando o volume total das estruturas ..	96
5.2.2.	Determinação da escala mais adequada	97
5.2.3.	Esquema final da aplicação piloto	101

5.2.4.	Dados do padrão	103
5.2.5.	Critério para redução da árvore de SSBlobs	103
5.2.6.	Classificação de estruturas	104
5.3.	IMPLEMENTAÇÃO	106
5.3.1.	Ferramentas utilizadas e módulos implementados.....	106
5.4.	RESULTADOS	107
CAPÍTULO 6		115
RESULTADOS.....		115
6.1.	EXPERIMENTOS REALIZADOS	115
6.2.	EFEITOS DE DIFERENTES RESOLUÇÕES.....	116
6.2.1.	Construção dos SSPS	117
6.2.2.	Comparação dos parâmetros nas diversas resoluções.....	125
6.2.3.	Redução da árvore baseada em <i>volume do SSBlob</i>	127
6.3.	IMAGENS COM NÍVEIS DE RUÍDO DIFERENTES	131
6.4.	CONTRASTE DE ESTRUTURAS.....	137
CAPÍTULO 7		153
CONCLUSÃO.....		153
7.1.	CONSIDERAÇÕES FINAIS.....	153
7.2.	CONTRIBUIÇÕES DO TRABALHO.....	158
7.3.	TRABALHOS FUTUROS.....	159
APÊNDICE I		163
TEMPOS DE PROCESSAMENTO		163
APÊNDICE II		165
ESCALAS DE SOBREVIVÊNCIA DE ESTRUTURAS.....		165
CASO 1. DETECÇÃO DE ESTRUTURAS EM SINAIS 1D FEITA A PARTIR DE LIMIAR		165
a.	Caso da estrutura isolada.....	165
b.	caso de 2 estruturas	172
CASO 2. DETECÇÃO DE ESTRUTURAS EM IMAGENS 2D FEITA A PARTIR DO OPERADOR <i>UMBILICITY</i>		180
APÊNDICE III		189
INTERAÇÃO ENTRE OS MÓDULOS IMPLEMENTADOS.....		189
APÊNDICE IV		191
ANÁLISE DA INFLUÊNCIA DE τ.....		191
CASO 1. IMAGEM DE SIMULAÇÃO COM DOIS CÍRCULOS		191
CASO 2. IMAGEM DO <i>PHANTOM</i> MCAT		193
REFERÊNCIAS BIBLIOGRÁFICAS		197

Lista de Figuras

CAPÍTULO 1 **1**

- Figura 1.1.** O urso atrás da árvore. Nesta figura, a evidência é suficiente para produzir a hipótese conceitual de um urso; mas não é suficiente para vê-lo perceptualmente. Figura de Gregory (1990). 2
- Figura 1.2.** Exemplo do efeito de escala na visualização de imagens médicas. Em (a), apresenta-se uma imagem de mamografia, que contém uma região com microcalcificações (região delimitada pelo quadrado branco). Entretanto, a resolução da imagem não permite visualizar as microcalcificações. A região marcada é mostrada em (b) com uma resolução maior, e, nesta resolução, é possível visualizar as microcalcificações (pequenos pontos mais claros na imagem). Imagens de Netsch e Peitgen (1999). 4
- Figura 1.3.** Exemplo do efeito de escala na visualização de imagens médicas. Em (a) apresenta-se uma imagem de Medicina Nuclear, que contém regiões que são indicativas de metástase (na região delimitada pelo quadrado). Entretanto a presença de ruído torna difícil a identificação dos pontos. A região marcada é mostrada em (b) e (c) após ter sofrido um processo de suavização, mais intenso em (c). Nestas imagens, a identificação visual das regiões de metástase é mais fácil. Imagens de Godtlibsen et al (2004). 5

CAPÍTULO 2 **11**

- Figura 2.1.** Corte transversal de tórax – imagem de tomografia computadorizada por raios X. A seta branca aponta para o ramo da aorta. (Imagem adquirida no Serviço de Radiologia da Divisão de Diagnóstico por Imagens – Instituto do Coração – HCFMUSP). 13
- Figura 2.2.** Etapas de processamento para reconhecimento e interpretação de estruturas em imagens digitais. Figura adaptada de Gonzales (2000). 16
- Figura 2.3.** Imagem na qual o valor de intensidade do pixel é dado pela altura da superfície nesse ponto. Figura obtida a partir da imagem 2.4, pela aplicação de uma transformação utilizando o software AVS. 18
- Figura 2.4.** A mesma imagem de 2.3, com representação em níveis de cinza. 18
- Figura 2.5.** Relação entre os níveis de representação e os níveis de processamento. Figura adaptada, a partir da figura 2.2, para ilustrar a relação entre os níveis de processamento (Gonzales, 2000) e a classificação de níveis de imagens (Ballard, 1982). 20
- Figura 2.8.** Espaço de classificação para estratégias de reconhecimento de estruturas proposto por Suetens et al (1992). 21

CAPÍTULO 3 **33**

- Figura 3.1.** Esquema de espaço de escalas em 3D e 2D. À esquerda, é apresentado o espaço de escalas de uma imagem sintética (gerada por software desenvolvido neste trabalho), que contém três cubos. À direita, o espaço de escalas de uma imagem cardíaca obtida por ressonância magnética (imagem adquirida no Serviço de Ressonância Magnética da Divisão de Diagnóstico por Imagens – Instituto do Coração – HCFMUSP). Os espaços de escalas foram

- obtidos pela convolução da imagem original com a gaussiana (equação 3.5), com os valores de σ descritos pela equação 3.7. 37
- Figura 3.2.** Dezesseis níveis do espaço de escalas linear de um corte de tórax por ressonância magnética com $\tau = 0,19$ (Imagem adquirida no Serviço de Ressonância Magnética da Divisão de Diagnóstico por Imagens – Instituto do Coração – HCFMUSP). 41
- Figura 3.3.** (a) Doze cortes de um volume cardíaco de ressonância magnética – dimensões 256x256x10x12 - ao longo do ciclo cardíaco. (b) derivadas parciais obtidas pela abordagem de espaço de escalas utilizando $\sigma = 1,42$: A, B, C, e D são, respectivamente, as derivadas nas direções y, x, z e no tempo. Para o cálculo das derivadas, realizou-se uma interpolação linear nas direções z e t no conjunto de imagens da figura a. (Imagens adquiridas no Serviço de Ressonância Magnética – Divisão de Diagnóstico por Imagem - Instituto do Coração – HCFMUSP). 43
- Figura 3.4.** a) um corte 2D de um volume 3D cardíaco de ressonância magnética. Resolução espacial de 60x60x10, resolução temporal de 12 imagens por ciclo cardíaco. b), c) e d) módulo do gradiente para $\sigma = 1,42$, $\sigma = 2,72$ e $\sigma = 4,48$, respectivamente. (Imagem adquirida no Serviço de Ressonância Magnética – Divisão de Diagnóstico por Imagem - Instituto do Coração – HCFMUSP). 44
- Figura 3.5.** Doze escalas do espaço de escalas não linear utilizando difusão com condutância variável, construídas a partir da proposta de Black e Sapiro. A imagem no canto superior esquerdo é a imagem original. (Imagem adquirida no Serviço de Ressonância Magnética – Divisão de Diagnóstico por Imagem - Instituto do Coração – HCFMUSP). 49
- Figura 3.6.** Imagem sintética simples (criada por software desenvolvido neste trabalho) utilizada para verificação do desempenho das rotinas de geração do espaço de escalas em 3 resoluções diferentes. 56
- Figura 3.7.** Tempos de processamento para criação do espaço de escalas com diferentes níveis, para a imagem apresentada na figura 3.7, em três resoluções: 64 x 64, 128 x 128 e 256 x 256 pixels. $\tau = 0,19$. A tabela com os valores dos tempos é apresentada no Apêndice I. Os valores foram obtidos em um servidor Sun Ultra Enterprise 450. 57
- Figura 3.8.** Nove níveis do espaço de escalas para o *phantom* MCAT, construído com $\tau = 0,19$. Representação em isosuperfície utilizando o AVS®. 58
- Figura 3.9.** Comparação dos tempos de processamento em dois servidores para criação do espaço de escalas com diferentes níveis, para o volume 3D apresentado na figura 3.9. A tabela com os valores dos tempos é apresentada no Apêndice I. 58

CAPÍTULO 4

61

- Figura 4.1.** Figura 4.1. (a) Imagem sintética (criada por software desenvolvido neste trabalho) contendo duas estruturas com intensidade maior que o fundo e duas estruturas com intensidade menor, visualizadas em níveis de cinza; (b) Visualização em superfícies de nível da imagem apresentada em a, na qual o valor de intensidade de cada ponto (x,y) determina a coordenada z correspondente. À esquerda da imagem (a) apresenta-se a escala de níveis de cinza: intensidades mais baixas são associadas ao preto e intensidades mais altas são associadas ao branco. 63
- Figura 4.2.** . (a) Imagem de ventriculografia cintilográfica em um espaço de escalas com 7 níveis. A imagem inferior é a original e as subsequentes são versões suavizadas progressivamente; (b) representação de isosuperfície da imagem mostrada em (a). A tabela de cores é apresentada no canto superior esquerdo. Valores de intensidade mais altos correspondem aos tons de vermelho

- e os de intensidade mais baixa aos tons de azul. (Imagem obtida no Serviço de Medicina Nuclear e Imagem Molecular do Instituto do Coração – HCFMUSP.) 64
- Figura 4.3.** Ilustração do conceito de blob de nível de cinza (blob claro). Na figura são mostrados os pontos relevantes para a determinação do blob: extremos e ponto de sela. Figura extraída de Coulon et al (1997). 65
- Figura 4.4.** (a) Imagem sintética (criada por software desenvolvido neste trabalho) contendo três estruturas com intensidades maiores que o fundo. (b) Regiões de suporte e as linhas de base. (c) Visualização em isosuperfície da imagem (a), mostrando os três máximos locais, que são o ponto de partida para delimitação dos blobs. Em (d) e (e), são apresentados os três blobs extraídos da imagem (c). Nestas figuras pode-se visualizar o conceito de blob de nível de cinza para uma imagem 2D: uma estrutura tridimensional que, a partir de um máximo local se estende até encontrar um ponto de inflexão. Os volumes apresentados em preto nas figuras (d) e (e) representam o volume do blob. A representação em isosuperfície utilizada em (c), (d) e (e) foi obtida utilizando o software AVS®..... 66
- Figura 4.5.** (a) Dois picos de alto contraste em um sinal 1D. (b) Aos picos iniciais 1 e 2 são superpostos picos de escalas menores. Os picos iniciais 1 e 2 não são mais detectados como blobs únicos, se considerados em uma única escala. Figura retirada de Lindeberg (1993) 67
- Figura 4.6.** (a) Seis escalas da imagem sintética apresentada na figura 4.4.a. (b) Visualização das figuras em superfícies de intensidade. (c) Visualização dos blobs (assinalados em branco) nas diversas escalas. Pode-se observar que os blobs 1 e 2 vão se fundindo até que, na escala 5, eles se agrupam para formar um novo blob. Na escala 6, esse novo blob vai se agrupar com o blob 3. (d) Visualização dos efeitos descritos em (c) para os blobs 1 e 2 em curvas de intensidade em função da posição, para as linhas mostradas em (a)..... 69
- Figura 4.7.** Blobs de nível de cinza extraídos de uma imagem torácica obtida por ressonância magnética. Na linha superior, a imagem é apresentada em três níveis do espaço de escala. Os GLBlobs extraídos a partir de cada uma dessas imagens são apresentados na linha inferior. Na imagem original os blobs escuros refletem principalmente o ruído presente na imagem. Na imagem de escala baixa começam a aparecer as estruturas anatômicas representadas pelos blobs (pulmões, artérias, veias e cavidades cardíacas), porém ainda formadas por estruturas desconexas. Na escala alta os blobs formam estruturas puras: pode-se distinguir, por exemplo, parte do pulmão esquerdo (a) e cavidades cardíacas (b). GLBlobs extraídos usando as expressões 4.4, 4.6 e 4.7. (Imagem adquirida no Serviço de Ressonância Magnética – Divisão de Diagnóstico por Imagem - Instituto do Coração – HCFMUSP).. 69
- Figura 4.8.** Tipos de eventos de blobs: (a) aniquilação; (b) acoplamento; (c) criação; (d) separação. Figura retirada de Coulon et al (1997). 70
- Figura 4.9.** Exemplo de estrutura de árvores para o espaço de escalas mostrado em 4.6.^a Entre os níveis 0 (imagem original) e 1 ocorrem diversos eventos de blob: muitas aniquilações e acoplamentos, os quais vão formar os blobs 3,4,5. Para a construção do SSBS, a análise é iniciada na escala mais alta e por isso, os números dos SSBlobs são diferentes em relação àqueles da figura 4.6. 72
- Figura 4.10.** Exemplo de *prunning* da árvore de SSBlobs. Figura retirada de Coulon et al (1997) 75
- Figura 4.11.** Tempos de processamento para obtenção dos GLBlobs em espaços de escalas com diferentes níveis, para a imagem apresentada na figura 3.8 (capítulo 3), em três resoluções: 64 x 64, 128 x 128 e 256 x 256 pixels. $\tau = 0,19$. A tabela com os valores dos tempos é apresentada no apêndice I. Tempos obtidos no servidor Sun Ultra Enterprise 450..... 81

Figura 4.12. Comparação dos tempos de processamento em dois servidores para detecção dos GLBlobs em espaços de escalas com diferentes níveis, para o volume 3D do <i>phantom</i> MCAT apresentado na figura 3.9. A tabela com os valores dos tempos é apresentada no apêndice I.	82
Figura 4.13. Visualização em isosuperfície dos GLBlobs detectados em 12 níveis do espaço de escalas para o volume do <i>phantom</i> MCAT. $\tau = 0.19$	83
Figura 4.14. Visualização dos GLBlobs do <i>phantom</i> MCAT em várias escalas, para dois cortes distintos do volume. Os volumes à direita mostram a posição, no <i>phantom</i> , dos cortes apresentados.	83
Figura 4.15.: Superposição dos blobs encontrados para os 16 níveis do espaço de escalas e a imagem original. Blobs extraídos em 10 níveis: $\sigma_1 = 1,19$; $\sigma_2 = 1,41$; $\sigma_3 = 1,68$; $\sigma_4 = 2,00$; $\sigma_5 = 2,37$; $\sigma_6 = 2,82$; $\sigma_7 = 3,35$; $\sigma_8 = 3,97$; $\sigma_9 = 4,72$; $\sigma_{10} = 5,61$. A seta no nível 10 indica a seção da aorta, que não foi identificada nesta escala como um GLBlob.	84
Figura 4.16. Imagens de blobs mostradas na figura 4.15. As setas finas indicam as regiões mais proeminentes, determinadas pelo método proposto. As duas regiões indicadas pelas setas grossas na escala 10 são formações originadas por ruído que sobrevivem até escalas mais altas.	85
 CAPÍTULO 5	87
Figura 5.1. Esquema global das etapas e níveis de representação envolvidos no método proposto.	88
Figura 5.2. Imagem de teste bidimensional, gerada a partir do <i>phantom</i> MCAT com resolução de 64 x 64 pixels, na qual foram simuladas 3 estruturas com intensidade menor do que o fundo. Na tabela de cores utilizada, apresentada à direita da figura, os valores mais baixos de intensidade são representados pelo azul.	90
Figura 5.3. (a) e (c) Quatorze níveis do espaço de escalas da imagem apresentada na figura 5.2, $\tau = 0,19$. (b) e (d) Imagens com os GLBlobs, detectados pelos operadores descritos no capítulo 4, em cada nível do espaço de escalas.	90
Figura 5.4. <i>Scale Space Primal Sketch</i> do espaço de escalas da imagem apresentada na figura 5.3. (a) GLBlobs em escalas diferentes com a mesma cor formam um SSBlob. Em (b) são apresentadas as codificações de cores para os 23 SSBlobs identificados.	91
Figura 5.5. Exemplo de relação representada pela estrutura de árvore proposta.	93
Figura 5.6. Representação em árvore do SSPS apresentado na figura 5.4.a. Foi mantida a tabela de cores dos SSBlobs da figura 5.4.b. Os números acima dos nós representam o parâmetro volume do SSBlob. Os três nós que representam as estruturas presentes na imagem original são destacados na figura.	93
Figura 5.7. Esquema global do método proposto para a aplicação piloto.	95
Figura 5.8. Exemplo de uma imagem 64 x 64 pixels. As quatro estruturas presentes são identificadas pelos números sobrepostos. Na tabela 5.1 são apresentadas as dimensões das quatro estruturas e na tabela 5.2, as faixas de sobrevivência de cada uma das estruturas. .	99
Figura 5.9. Esquema global do método proposto para a aplicação piloto, incluindo a redução da árvore e escolha da escala adequada.	102
Figura 5.10. Exemplo de imagem com 4 estruturas. A estrutura procurada é Φ , que, na escala n , é caracterizada por um volume V_Φ . As estruturas 1, 2 e 3 são caracterizadas por seus volumes	

V_1 , V_2 e V_3 . Os parâmetros $D_{1(V_1)}$, $D_{2(V_2)}$, $D_{3(V_3)}$ denotam as distâncias entre a estrutura Φ e as estruturas 1, 2 e 3, respectivamente. Os parâmetros $\theta_{1(V_1, V_2)}$, $\theta_{2(V_2, V_3)}$, $\theta_{3(V_1, V_3)}$ são os ângulos formados, respectivamente, por (1, Φ , 2), (2, Φ , 3) e (1, Φ , 3)	104
Figura 5.11. Imagens teste para visualização da árvore de SSBlobs, obtidas pela manipulação do <i>phantom</i> MCAT. Resolução das imagens 64x64 pixels.	108
Figura 5.12. Blobs detectados nos espaços de escala das imagens apresentadas na figura 5.11, com $\tau = 0,19$	110
Figura 5.13. Árvores de SSPS obtida para as imagens image1 (esquerda), image2 (central) e image3 (direita) da figura 5.11. O nó Raiz é um artifício computacional para representar todos os nós como pertencentes à mesma árvore. O número inicial identifica o número do nó e as informações entre colchetes são as escalas de aparecimento e desaparecimento e o volume do SSBlob. Os nós marcados com um círculo são aqueles que representam as estruturas reais da imagem. O número entre parênteses, à direita desses nós, indica qual estrutura é representada por ele, segundo numeração das estruturas apresentada na figura 5.11.	112
Figura 5.14. Árvores de SSPS obtida para as imagens image4 (esquerda), e image5 (direita) da figura 5.11	113

CAPÍTULO 6

115

Figura 6.1. Imagem do <i>phantom</i> MCAT, com indicação das estruturas avaliadas.....	116
Figura 6.2. Espaço de escalas para a imagem apresentada em 6.1. com resolução 64x64. (a) Blobs no espaço de escalas, $\tau = 0,19$. (b) árvore de SSPS. São identificados na árvore os nós que correspondem aos órgãos na figura 6.1.....	117
Figura 6.3. Espaço de escalas para a imagem apresentada em 6.1 com resolução 128x128. (a) Blobs no espaço de escalas, $\tau = 0,19$. (b) árvore de SSPS.	118
Figura 6.4. Espaço de escalas para a imagem apresentada em 6.1 com resolução 128x128. (a) Blobs no espaço de escalas, $\tau = 0,22$. (b) árvore de SSPS.	119
Figura 6.5. Espaço de escalas para a imagem apresentada em 6.1 com resolução 256x256. (a) Blobs no espaço de escalas, $\tau = 0,19$. (b) árvore de SSPS, na qual são mostrados apenas os nós do primeiro nível.....	120
Figura 6.6. Detalhe da árvore de SSPS apresentada na figura 6.5.b.....	121
Figura 6.7. Espaço de escalas para a imagem apresentada em 6.1 com resolução 256x256. (a) Blobs no espaço de escalas, $\tau = 0,22$. (b) árvore de SSPS, na qual são mostrados apenas os nós do primeiro nível.....	122
Figura 6.8. Detalhe da árvore de SSPS apresentada na figura 6.7.b. Neste detalhe, apresentam-se os ramos da árvore filhos dos nós 0, 1 e 2.....	123
Figura 6.9. Espaço de escalas para a imagem apresentada em 6.1 com resolução 256x256. (b) Blobs no espaço de escalas, $\tau = 0,25$. (a) árvore de SSPS.	124
Figura 6.10. Razão entre os volumes para espaços de escala da imagem apresentada em 6.1, obtidos a partir de diferentes resoluções e construídos utilizando 2 valores de τ . O valor esperado 1 (VE.1) para a razão entre os volumes nas resoluções 256/64 é 16 e o valor esperado 2 (VE.2) para a razão entre os volumes nas resoluções 256/128 (para os dois valores de τ) e 128/64 é 4.	125
Figura 6.11. Razão entre os volumes para espaços de escala, sem ruído.	126

Figura 6.12. Redução da árvore de SSBlobs pela aplicação do casamento utilizando o parâmetro volume do SSBlob para a estrutura 2.....	128
Figura 6.13. Redução da árvore de SSBlobs pela aplicação do casamento utilizando o parâmetro volume do SSBlob para a estrutura 3.....	129
Figura 6.14. Redução da árvore de SSBlobs pela aplicação do casamento utilizando o parâmetro volume do SSBlob para a estrutura 4.....	130
Figura 6.15. Conjunto de cinco imagens com diferentes níveis de ruído. A coluna (a) apresenta as imagens originais sem ruído, a coluna (b) a imagem de ruído baixo, a coluna (c) a imagem de ruído médio e a coluna (d) a imagem de ruído alto.....	132
Figura 6.16. Blobs detectados nos espaços de escala das imagens image1 (a) e image2 (b), obtidos com $\tau = 0,19$. Escala mais adequada para identificação da estrutura 2 nos dois conjuntos: 7.	133
Figura 6.17. Blobs detectados nos espaços de escala da imagem3, obtidos com $\tau = 0,19$. Escala mais adequada para detecção da estrutura 2: 6.	134
Figura 6.18. Blobs detectados nos espaços de escala das imagens image4 (a) e image5 (b), obtidos com $\tau = 0,19$. Escala mais adequada para detecção da estrutura 5 nos dois conjuntos: 7.	135
Figura 6.19. Imagens utilizadas para identificação de estruturas.	136
Figura 6.20. Imagem criada a partir do conjunto1 da Figura 6.19, sem a estrutura 5.	138
Figura 6.21. Imagens obtidas a partir da imagem apresentada na figura 6.20. Cada uma das imagens acima é obtida pela variação de contagem na região do tórax, que resulta na mudança de contraste das estruturas internas.....	138
Figura 6.22. Blobs detectados nos espaços de escala das imagens (a) imagem1 e (b) imagem2, mostradas na figura 6.21, com $\tau = 0,19$. O conjunto apresentado em (b) contém um número menor de escalas porque as imagens das escalas superiores são idênticas à da escala 12.	140
Figura 6.23. Blobs detectados nos espaços de escala das imagens (a) imagem3 e (b) imagem4, mostradas na figura 6.21, com $\tau = 0,19$	141
Figura 6.24. Blobs detectados nos espaços de escala da imagem5, mostradas na figura 6.21, com $\tau = 0,19$	142
Figura 6.25. Valores de contraste e CNR calculados para as imagens da figura 6.21. À esquerda são apresentados os valores calculados para a estrutura 2 em relação ao tórax e à direita, para o tórax em relação ao fundo. As imagens com ruído baixo são indicadas por \diamond , as imagens com ruído médio por X, e as imagens com ruído alto por Δ	143
Figura 6.26. Redução da árvore de SSBlobs da figura 4 ruído médio. Em (a), a redução foi feita com a similaridade em relação ao padrão do parâmetro volume de SSBlob em $\pm 20\%$. Em (b), a faixa de similaridade foi aumentada para $\pm 50\%$	145
Figura 6.27. Imagens obtidas a partir da imagem apresentada na figura 6.20. Cada uma das imagens acima é obtida pela variação de contagem na região do tórax e na região de fundo, que causam a mudança de contraste dos órgãos internos e a mudança de contraste tórax-fundo.	146
Figura 6.28. Valores de contraste e CNR calculados para as imagens da figura 6.27. As imagens com ruído baixo são indicadas por \diamond , as imagens com ruído médio por X, e as imagens com ruído alto por Δ	147
Figura 6.29. Blobs detectados nos espaços de escala da imagem1 mostrada na figura 6.26, com $\tau = 0,19$	148

Figura 6.30. Blobs detectados nos espaços de escala das imagens imagem2(a) e imagem3 (b), mostradas na figura 6.26, com $\tau = 0,19$ 149

Figura 6.31. Blobs detectados nos espaços de escala das imagens imagem4(a) e imagem5 (b), mostradas na figura 6.26, com $\tau = 0,19$ 150

APÊNDICE II **165**

Figura AII.1. Função gaussiana unidimensional..... 166

Figura AII.2. Sinal unidimensional de uma onda quadrada..... 166

Figura AII.3. Função normal com média zero e desvio padrão 1. A área destacada sob a curva é dada por: $1/\sqrt{2\pi} \int_{-b/2\sigma}^{b/2\sigma} e^{-\frac{z^2}{2}} dz$ 168

Figura AII.4. Função normal com média zero e desvio padrão 1. A área destacada sob a curva é dada por: $1/\sqrt{2\pi} \int_{-b/2\sigma}^0 e^{-\frac{z^2}{2}} dz$ 168

Figura AII.5. Função unidimensional utilizada para testar os resultados obtidos nas relações para b/σ 171

Figura AII.6. Resultado da convolução da função dada por AII.16 e a gaussiana com $\sigma = 50$ (condição AII.14 – pontos de borda). A partir deste valor de σ , a estrutura detectada utilizando o limiar $T = a/3$ é menor do que a original. Os resultados foram ajustados para que o valor central da função seja zero. 172

Figura AII.7. Resultado da convolução da função dada por AII.16 e a gaussiana com $\sigma = 58$ (condição AII.15 – ponto central). A partir deste valor de σ , a estrutura não é mais detectada. Os resultados foram ajustados para que o valor central da função seja zero. 172

Figura AII.8. Sinal uni-dimensional, no qual se deseja detectar as duas ondas quadradas..... 173

Figura AII.9. Sequência de eventos em um espaço de escalas construído para um sinal unidimensional $f(x)$ apresentado em (a). (b), (c) e (d) mostram níveis mais altos desse espaço de escalas. A detecção das estruturas é feita utilizando a função limiar. Nas figuras (b) e (c) as estruturas presentes no sinal original são detectadas como estruturas distintas. Em (d) há um acoplamento, devido ao borramento produzido pela convolução com a gaussiana. 174

Figura AII.10. Função normal com média zero e desvio padrão 1. As áreas destacadas sob a curva são dadas por: $1/\sqrt{2\pi} \int_{-3b/2\sigma}^{-b/2\sigma} e^{-\frac{z^2}{2}} dz$ e $1/\sqrt{2\pi} \int_{b/2\sigma}^{3b/2\sigma} e^{-\frac{z^2}{2}} dz$ 175

Figura AII.11. Função erro, cujas soluções fornecem os valores de σ para a condição AII.12. Função obtida utilizando o software Matlab®..... 177

Figura AII.12. Função unidimensional utilizada para testar os resultados obtidos nas relações para b/σ , no caso de duas estruturas. 178

Figura AII.13. Espaço de escalas da função apresentada na figura AII.12 para oito valores de σ 178

Figura AII.14. Resultado da convolução da função dada por AII.21 e a gaussiana com $\sigma = 106.5$. A partir deste valor de σ , nenhuma estrutura é detectada no sinal. Os resultados foram ajustados para que o valor central da função seja zero.	179
Figura AII.15. Resultado da convolução da função dada por AII.21 e a gaussiana com $\sigma = 26$. A partir deste valor de σ , as duas estruturas se acoplam. Os resultados foram ajustados para que o valor central da função seja zero.	179
Figura AII.16. Imagem bidimensional com uma estrutura de raio R e amplitude a no centro da imagem.	180
Figura AII.17. Processo de detecção de estruturas através da utilização de um operador $h(x,y)$.	180
Figura AII.18. Função $I(R/\sigma)$ para o ponto $(0,0)$. A solução para $I = 0$ fornece o valor de σ para a condição AII.38. Função obtida utilizando o software Matlab®.	185

APÊNDICE IV

191

Figura AIV.1. Imagem simulada, com resolução de 64×64 pixels, formada por um fundo uniforme e duas estruturas circulares.	191
Figura AIV.2. Espaços de escala construídos com diferentes valores de τ , para a imagem mostrada em AIV.1.	192
Figura AIV.3. Visualização em níveis de cinza do corte do <i>phantom</i> MCAT apresentado na figura 5.2.	193
Figura AIV.4. Espaços de escala construídos com diferentes valores de τ , para a imagem mostrada em AIV.3.	194

Lista de Tabelas

CAPÍTULO 5	87
Tabela 5.1. Dimensões e contagem média das quatro estruturas, tórax e fundo da imagem apresentada na figura 5.8.	100
Tabela 5.2. Faixa de sobrevivência no espaço de escalas das quatro estruturas da imagem apresentada na figura 5.8. Na segunda coluna da tabela são indicados os valores de σ de cada nível do espaço de escalas, em pixels. Na terceira coluna são indicadas as faixas de sobrevivência de cada estrutura. Os níveis de escala demarcados pelas duas linhas são aqueles nas quais há sobreposição da presença de todas as estruturas reais da imagem.	100
Tabela 5.3. Dimensões e contagem média das estruturas das imagens image1, image2 e image3, mostradas na figura 5.11.	108
Tabela 5.4. Dimensões e contagem média das estruturas das imagens image4 e image5, mostradas na figura 5.11.	108
CAPÍTULO 6	115
Tabela 6.1. Experimentos realizados	115
Tabela 6.2. Volumes (em pixels) encontrados para as quatro estruturas nas diferentes resoluções e com espaços de escala construídos a partir de parâmetros distintos	125
Tabela 6.3. Parâmetros das imagens geradas com diferentes níveis de ruído. “ σ_{sinal} ” é o desvio padrão da imagem original, “ $\sigma_{\text{ruído}}$ ” é o desvio padrão da imagem de ruído. O nível de ruído é caracterizado pela SNR, a razão sinal-ruído, dada pela equação 6.1.	131
Tabela 6.4. Resultados da etapa final de identificação dos nós do SSPS para as imagens com três níveis de ruído diferentes. As duas colunas para cada nível de ruído indicam a faixa de variação permitida no volume de SSBlob, em relação ao padrão, na etapa de simplificação da árvore. \checkmark indica resultado correto na identificação e X representa resultado incorreto.....	137
Tabela 6.5. Valores de razão contraste-ruído e contraste da estrutura 2 em relação ao tórax . .	139
Tabela 6.6. Resultados da etapa final de identificação da estrutura 2 nas imagens com diferentes níveis de contraste e ruído. \checkmark indica resultado correto na identificação e X representa resultado incorreto e ϕ indica sem resultado.	144
Tabela 6.7. Resultados da etapa final de identificação da estrutura 2 nas imagens com diferentes níveis de contraste e ruído. \checkmark indica resultado correto na identificação e X representa resultado incorreto e ϕ indica sem resultado.	151
APÊNDICE I	163
Tabela AI.1. Tempos de processamento dos resultados apresentados na figura 3.6.	163
Tabela AI.2. Tempos de processamento dos resultados apresentados na Figura 3.8.	163
Tabela AI.3. Tempos de processamento dos resultados apresentados na Figura 4.11.	164
Tabela AI.4. Tempos de processamento dos resultados apresentados na Figura 4.12.	164

APÊNDICE II**165**

Tabela AII.1. Valores de área sob a curva normal, com a porção de área $(-\infty \rightarrow 0)$ subtraída.	169
Tabela AII.2. Valores de área sob a curva normal, com a porção de área $(-\infty \rightarrow -b/2\sigma)$ subtraída.	170
Tabela AII.3. Valores de σ para os quais o objeto de raio $R = 1.5$ sobrevive, para três níveis de contraste diferentes.	187

Lista de Símbolos

s	parâmetro de escalas; característica da escala na qual a imagem está sendo observada.
$g(\vec{x}; \sigma)$	função gaussiana.
σ	parâmetro da função gaussiana; relaciona-se com s , por: $\sigma^2 = s$.
τ	parâmetro utilizado para construção do espaço de escalas, que varia linearmente ao longo das escalas; relaciona-se com σ por $\sigma_n = \varepsilon e^{n \cdot \tau}$, $n \in N$.
ε	representa a resolução espacial da imagem original.
ε_{ij}	tensor de Levi-Civita.
δ_{ij}	tensor de Kronecker.
L	operador laplaceano.
U_{2D}	operador <i>umbilicity</i> em 2D.
U_{3D}	operador <i>umbilicity</i> em 3D.

Glossário

1D	Uma dimensão.
2D	Duas dimensões.
3D	Três dimensões.
4D	Seqüência temporal de imagens 3D.
AVS	<i>Advanced Visual System</i> : Ambiente para visualização interativa e processamento de imagens.
GLBlob	Blob de nível de cinza: regiões da imagem mais claras ou mais escuras do que a sua vizinhança.
LGN	Núcleo geniculado lateral no tálamo.
MCAT	<i>Mathematical Cardiac Torso. phantom</i> antropomórfico, desenvolvido na Universidade da Carolina do Norte, que tem sido utilizado em pesquisa de tomografia por emissão de fótons.
SSBlob	Blob de espaço de escalas.
SSPS	<i>Scale Space Primal Sketch</i> . Estrutura de dados em múltiplas escalas.

Trabalhos publicados

Trabalhos publicados em periódicos ou eventos nacionais.

- Gutierrez, M.A., Rebelo, M. F. S., Furuie, S.S., Cattani, C., Sauerbeck, H.P., 1998. Quantification of Myocardial Motion in Cine-MRI. In: *IV Fórum Nacional de Ciência e Tecnologia em Saúde, 1998, Curitiba*, 467-468.
- Rebelo, M.S., Gutierrez, M. A., Furuie, S.S., Moura, L., 2001. Incorporation of geometrical information to identify cardiac structures in MRI. In: *Proceedings of XIV Brazilian Symposium on Computer Graphics and Image Processing, 2001, Florianópolis*.
- Rebelo, M.S., Furuie, S.S., Gutierrez, M.A., Moura, L., 2004. Identificação Automática de Estruturas em Imagens Médicas. In: *Anais do IX Congresso Brasileiro de Informática em Saúde*, 337-342.

Trabalhos publicados em periódicos ou eventos internacionais.

- Furuie, S.S., Rebelo, M.S., Gutierrez, M.A., Melo, C.P., 1998. Assessment of 3D Myocardium Segmentation in MRI using endocardium layer expansion model. *Computers in Cardiology*, 25, 661-664.
- Rebelo, M.S., Gutierrez, M.A., Furuie, S.S., Moura, L., 1998. Multiscale Method to isolate cardiac structures in MRI. *Computers in Cardiology*, 25, 501-504.
- Gutierrez, M. A., Rebelo, M. S., Furuie, S.S., 1998. A multiresolution method to computing myocardial motion. In: *Proceedings of IEEE International Symposium on Time-frequency & Time-scale Analysis, 1998, Pittsburg*, 89-92.
- Gutierrez, M.A., Rebelo, M.S. Cattani, C., Sauerbeck, H.P., Furuie, S.S., 1998. Quantitative myocardial kinetic energy as a physiological parameter in cine-MRI. In: *Proceedings of 20th International Conference of the IEEE Engineering in Medicine and Biology Society, 1998, Hong Kong*, 488-491.
- Gutierrez, M.A., Rebelo, M.S., Furuie, S.S., Pozzo, L., Meneguetti, J.C., Melo, C.P., 2000. The assessment of myocardial motion in gated SPECT using a multiresolution technique. *Computers in Cardiology*, 27, 303-306.
- Rebelo, M.S., Gutierrez, M.A., Furuie, S.S., Moura, L., 2000. Extraction of cardiac structures through the incorporation of a priori knowledge in a multi-scale approach. *Computers in Cardiology*, 27, 611-614.
- Gutierrez, M.A., Rebelo, M.S., Furuie, S.S., Pozzo, L., Meneguetti, J.C., Melo, C.P., 2001. Automatic left ventricle wall motion detection in gated-SPECT perfusion images. *Medical Imaging 2001 Physiology And Function From Multidimensional Images*, 4321, 92-99.

Gutierrez, M.A., Rebelo, M.S., Furuie, S.S., Meneguetti, J.C., 2003. Automatic quantification of three-dimensional kinetic energy in gated myocardial perfusion single-photon-emission computerized tomography improved by a multiresolution technique. *Journal of Electronic Imaging*, 12(1), 118-124.

Gutierrez, M. A., Furuie, S.S., Rebelo, M.S., Meneghetti, J.C., 2005. Automatic methods to analyze and quantify left ventricle parameters by means of SPECT. In: Leondes, C. (Ed.). *International Volumes on Medical Imaging Systems*. World Scientific Publishing CO. (no prelo).

Rebelo, M.S., Furuie, S.S., Gutierrez, M. A., Moura, L., 2005. Automatic Identification of Medical Structures. *Progress in Biomedical Optics Imaging*, 25(6), 522-529.

Trabalho submetido

Rebelo, M.S., Furuie, S.S., Gutierrez, M. A., Costa, E.T., Moura, L. (2005 submetido) Finding structures in medical images by scale-space. Submetido a: *Physics in Medicine and Biology*. Institute of Physics Publishing.

You can never solve a problem on the level on which it was created

- Albert Einstein

Capítulo 1

Introdução

O campo de diagnóstico em Medicina sofreu uma revolução com a descoberta dos raios X por Röntgen em 1895. A partir daí, os médicos puderam **ver** estruturas internas do corpo humano sem necessidade de abri-lo. No decorrer do último século, novas formas de obter informações do interior do corpo humano foram desenvolvidas. Atualmente, pode-se obter excelentes informações anatômicas através das técnicas de Tomografia Computadorizada por raios X e Ressonância Magnética, ou ainda informações funcionais utilizando técnicas como Ultra-sonografia, Medicina Nuclear ou Ressonância Magnética Funcional. O desenvolvimento e a utilização desses métodos de formação de imagens médicas naturalmente levaram ao desenvolvimento de técnicas para processamento e visualização dos dados gerados. A análise de imagens médicas é hoje uma área importante dentro das disciplinas de Processamento de Imagens Digitais e Visão Computacional.

O desenvolvimento de sistemas automáticos para processamento de imagens médicas, que atuem efetivamente como um agente auxiliar ao diagnóstico médico, é um objetivo que vem sendo perseguido há tempos pelos pesquisadores da área. A automatização de tarefas de análise de imagem pode produzir resultados muito interessantes como: diminuição do tempo gasto pelos especialistas, diminuição das variações intra e inter-observador, segunda opinião para médicos não-especialistas e em sistemas de ensino.

Qualquer sistema automático para análise e visualização de imagens envolve a identificação de objetos e, freqüentemente, o estabelecimento de relações entre eles. A

identificação automática de estruturas é uma área de processamento de imagens que ainda apresenta grandes desafios. Em tarefas que envolvem basicamente atividades de cálculo, a capacidade de processamento do computador é incomparavelmente superior à capacidade humana. Nas tarefas de reconhecimento e análise, entretanto, o homem possui uma habilidade até hoje não igualada por sistemas automáticos. Para uma determinada cena, os seres humanos possuem uma capacidade única de distinguir quais são os objetos significativos e, dentre eles, qual representa o foco de interesse para uma situação em particular. A utilização de hipóteses conceituais em adição à percepção visual é uma característica humana que permite a identificação de objetos, mesmo quando faltam elementos à cena para a realização dessa tarefa (Gregory, 1990). Um exemplo dessa capacidade é apresentado na figura 1.1, na qual se pode “ver” um urso atrás da árvore. Observando atentamente a figura, surge a questão: o urso é realmente “visto”? Ou ele apenas é “visto conceitualmente”?

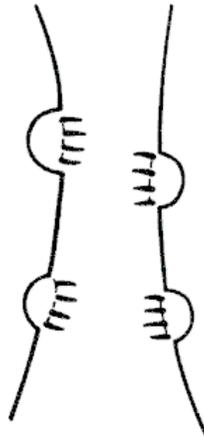


Figura 1.1. O urso atrás da árvore. Nesta figura, a evidência é suficiente para produzir a hipótese conceitual de um urso; mas não é suficiente para vê-lo perceptualmente. Figura de Gregory (1990).

Em sua rotina de análise de imagens, os médicos freqüentemente se deparam com imagens nas quais a percepção visual de alguma estrutura que está sendo estudada não é suficiente para a identificação. Eles necessitam, então, de hipóteses conceituais que permitam realizar essa tarefa. A cada novo exame analisado por um médico imagenologista, uma quantidade enorme de conhecimento, acumulada ao longo de sua carreira, é utilizada.

O sistema é retroalimentado, pois a cada novo exame, o médico acumula mais conhecimento sobre o problema específico. Um sistema de auxílio ao médico em sua tarefa de identificação e análise de estruturas deve também ser capaz de incorporar e utilizar conhecimento sobre o domínio do problema.

1.1. O problema da identificação automática

A transformação do sinal original - as imagens - em símbolos no domínio visual, ou seja a sua interpretação, é reconhecida como uma das tarefas mais importantes e mais difíceis no campo de análise de imagens, pelas seguintes razões:

- A forma pela qual os humanos percebem o conteúdo da imagem, agrupam características de imagens em objetos com significado ou inserem descrições semânticas em imagens ainda não é totalmente compreendida. Deste modo, não existe um modelo que possa ser utilizado como base para a automatização do procedimento de análise;
- Existem ainda muitas questões não solucionadas nas etapas de segmentação, extração de características que capturem o significado visual e semântico e no casamento da imagem a um modelo proposto baseado nas características extraídas, que tornam o problema de análise ainda mais desafiador;
- Os métodos propostos para solucionar problemas específicos raramente podem ser generalizados.

1.2. Identificação em imagens médicas

Em imagens médicas, assim como em outras áreas de aplicação de processamento de imagens, a identificação de estruturas constitui uma etapa importante em diversas aplicações, tais como visualização e planejamento cirúrgico, planejamento para procedimentos de radioterapia, identificação de tumores, má-formação e disfunções, classificação de órgãos, tecidos e células e recuperação de casos semelhantes em bases de imagens baseada em conteúdo.

A identificação de órgãos em imagens médicas apresenta alguns desafios diferenciados de outras aplicações, em função da especificidade desse tipo de imagem. Uma grande dificuldade é a criação de modelos eficientes para a representação de estruturas biológicas, as quais normalmente incluem formas bastante complexas, que não podem ser facilmente descritas. Além disso, em uma dada população, as mesmas estruturas variam muito em forma e tamanho.

1.3. Breve introdução à questão da escala em imagens

A existência de objetos de tamanhos diferentes em uma cena e a forma como o sistema de visão humano se comporta para se ajustar em diferentes tamanhos originou o estudo da questão da escala no processamento e visualização de imagens.

O efeito da escala pode ser observado em imagens digitais pela comparação de imagens obtidas em resoluções diferentes. Ao preconizar que uma imagem digital de mamografia necessita de uma resolução espacial de 4.000 x 4.000 pixels para que se possa atribuir a essa imagem qualidade diagnóstica, um médico está implicitamente afirmando que se a resolução da imagem for menor, detalhes poderão ser perdidos, porque uma imagem com baixa resolução apresenta um efeito de média ou borramento.

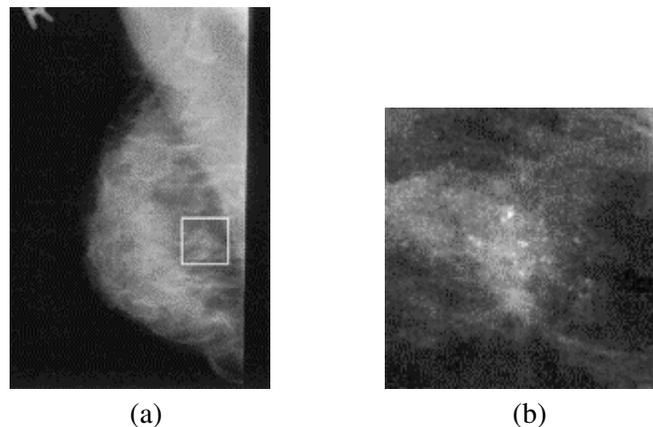


Figura 1.2. Exemplo do efeito de escala na visualização de imagens médicas. Em (a), apresenta-se uma imagem de mamografia, que contém uma região com microcalcificações (região delimitada pelo quadrado branco). Entretanto, a resolução da imagem não permite visualizar as microcalcificações. A região marcada é mostrada em (b) com uma resolução maior, e, nesta resolução, é possível visualizar as microcalcificações (pequenos pontos mais claros na imagem). Imagens de Netsch e Peitgen (1999).

Na figura 1.2, exemplifica-se esse conceito: em (a) apresenta-se uma imagem de mamografia com resolução baixa, na qual o efeito de borramento não permite visualizar as microcalcificações vistas em (b), que mostra a região destacada de (a) em uma resolução mais fina (Netsch e Peitgen, 1999).

Por outro lado, em imagens nas quais o ruído é muito alto, o efeito de borramento pode ajudar a detectar estruturas incertas na imagem original. Na figura 1.3, apresenta-se uma imagem de Medicina Nuclear, que é uma modalidade cuja característica é apresentar níveis altos de ruído. Em 1.3 (a), mostra-se uma imagem na qual os pontos brancos na região interior ao quadrado claro parecem ser indicativos de metástase. Entretanto a presença de ruído torna difícil a identificação dos pontos - especialmente aquele na região marcada com o círculo. O borramento, em dois níveis diferentes, gera imagens como as apresentadas em (b) e (c). A redução do ruído, neste caso, permite que os objetos procurados na cena - as regiões indicadoras de metástase - sejam realçados (Godtlielsen *et al.*, 2004).

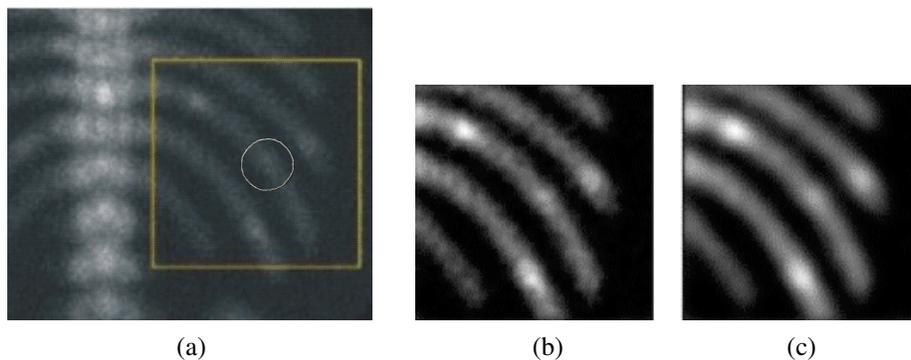


Figura 1.3. Exemplo do efeito de escala na visualização de imagens médicas. Em (a) apresenta-se uma imagem de Medicina Nuclear, que contém regiões que são indicativas de metástase (na região delimitada pelo quadrado). Entretanto a presença de ruído torna difícil a identificação dos pontos. A região marcada é mostrada em (b) e (c) após ter sofrido um processo de suavização, mais intenso em (c). Nestas imagens, a identificação visual das regiões de metástase é mais fácil. Imagens de Godtlielsen *et al.* (2004).

O ruído, no entanto, está sempre presente em imagens reais e, na falta de qualquer informação *a priori* sobre uma cena, não é possível saber qual informação constitui o sinal e qual informação constitui o ruído. Em uma escala muito baixa ou, de forma equivalente, em imagens de altíssima resolução, os dados de todos os pixels constituem, em princípio, o

sinal. Em uma escala mais alta, ocorre o efeito de média, indicando que o grau de suavização depende da escala. Embora não seja claro, à primeira vista, como definir o conceito de espaço de escalas, é normalmente aceito que a escala é uma “indicação” da distância a partir da qual um objeto é observado e, portanto, uma indicação do nível de detalhe que é possível visualizar (ter Haar Romeny, 1996).

1.4. Níveis de processamento

O processamento da imagem original pode ser realizado em múltiplos níveis de complexidade. É comum classificar as fases de processamento em três níveis: baixo, médio e alto (Gonzales, 2000; Niessen, 1997).

O processamento de baixo nível é totalmente baseado nos dados intrínsecos da imagem, sem a utilização de nenhum conhecimento *a priori* sobre as estruturas presentes. O principal objetivo do processamento de baixo nível é restringir a enorme quantidade de dados presentes na imagem original a um pequeno conjunto de parâmetros que permita a descrição completa da informação relevante contida na imagem (Gonzales, 2000; Sonka, 1998). Exemplos de parâmetros relevantes são o contraste local, a textura e a curvatura.

No processamento de nível intermediário a abordagem baseada nos dados da imagem ainda está presente, mas algum conhecimento *a priori* pode ser utilizado (Gonzales, 2000). A diferença para o processamento de baixo nível é que, baseado em um pequeno número de restrições, pode-se selecionar ou destacar informações relevantes para uma aplicação particular.

O processamento de alto nível é baseado em conhecimento, objetivos e estratégias de como melhor atingir esses objetivos. Utilizando conhecimentos prévios sobre a estrutura da imagem, os dados são sistematicamente avaliados. Hipóteses são confirmadas ou rejeitadas pelos dados. Em identificação automática de objetos, por exemplo, a informação contida em um banco de dados pode ser combinada com informações baseadas nos dados de imagem para um procedimento de casamento – ou acoplamento - ótimo. Nas rotinas de processamento de alto nível, os dados devem ser organizados de tal forma a facilitar buscas rápidas. A diferença entre a visão de alto nível e a visão de nível intermediário é a utilização

de conhecimento explícito sobre a fisiologia, o contexto ou modalidade da imagem sob análise (Niessen, 1997). O especialista humano possui a capacidade única de realizar, de forma efetiva, as três fases. Existem algoritmos de processamento de imagens que realizam as três fases e em sistemas de visão autônomos, todas as fases são necessárias.

1.5. Objetivo e estrutura do trabalho

Este trabalho pretendeu contribuir na área de identificação automática de imagens médicas, e teve por objetivo propor um método genérico para identificação de estruturas em imagens médicas, utilizando uma abordagem multi-resolução, o espaço de escalas. Pretendeu-se avaliar a adoção de uma representação de dados em múltiplas escalas que permitisse a inclusão de conhecimento sobre as estruturas em diversas escalas e ainda explorou-se a idéia de realizar o processamento em uma escala apropriada.

No método proposto, são abordados os três níveis de processamento, descritos no item 1.4. Na fase de visão de baixo nível, é construída uma representação dos dados em diversas escalas, sem imposição de nenhum conhecimento *a priori*, utilizando a teoria de espaço de escalas linear. No nível intermediário de processamento, são analisadas as imagens presentes em todas as escalas, com a detecção de características relevantes da imagem e com a criação de uma estrutura de dados que permita estabelecer relações entre as estruturas através das escalas. O resultado dessa fase é usado como entrada para um método de processamento de alto nível, que embute conhecimento sobre a estrutura procurada e que é baseado na existência de um padrão para essa classe de imagens.

No capítulo 2, são discutidas as questões teóricas relacionadas à identificação de estruturas. Apresenta-se o modelo de processamento em três etapas e os modelos de estruturas de dados adequados para cada uma dessas etapas. É feita, ainda, uma breve revisão dos trabalhos de identificação de estruturas em imagens médicas.

O método proposto para identificação é apresentado nos capítulos seguintes e pode ser resumido nos seguintes passos:

1. Suavização da imagem

A imagem é suavizada em diversos níveis. O conjunto de imagens suavizadas gera o chamado **espaço de escalas**. A idéia fundamental no conceito de espaço de escalas é que o grau de suavização pode revelar o tamanho dos objetos da imagem. Com o aumento do grau de suavização, os objetos começam a desaparecer da imagem, primeiro os menores e depois os maiores. A apresentação da teoria de espaço de escalas será feita no capítulo 3, com um pequeno histórico de seu desenvolvimento, as principais suposições, alguns detalhes da implementação realizada neste trabalho e apresentação de alguns resultados.

2. Escolha do detetor de características da imagem e construção da estrutura de dados

São determinadas estruturas da imagem, chamadas de **blobs**, que representam regiões mais claras ou mais escuras que a sua vizinhança, através da aplicação de operadores diferenciais. Uma estrutura de dados é descrita a partir da relação desses blobs ao longo do espaço de escalas. Essa estrutura é chamada de *Scale Space Primal Sketch*. Os operadores para determinação dos blobs e a forma de construção da estrutura de dados são apresentados no capítulo 4. Neste capítulo, são apresentados, ainda, detalhes de implementação e alguns resultados.

3. Inclusão de informações “a priori”

Na estrutura de dados proposta, embute-se informação *a priori* sobre a estrutura desejada. A partir do casamento de características com um padrão, é possível determinar, em imagens-teste, a estrutura procurada. O padrão é determinado pela aplicação do método proposto. Em imagens médicas, essa abordagem é bastante interessante pois permite, com a criação de padrões a partir de bancos de dados que contenham informações sobre condições normais e patológicas, a construção de mecanismos para verificação de normalidade ou anormalidade de um sistema ou órgão em estudo. O tipo de informação embutida depende do tipo de aplicação. No capítulo 5, é apresentada uma aplicação piloto, na qual utilizam-se informações sobre a geometria da estrutura procurada e o contexto na imagem na qual ela está inserida.

No capítulo 6, é feita a apresentação dos resultados obtidos pela aplicação do método em imagens de *phantom*. São analisados alguns parâmetros, como ruído, escala da imagem e contraste. No capítulo 7, é feita uma discussão sobre os resultados e são apresentadas as conclusões do trabalho.

"It takes a lot of imagination to be a good photographer. You need less imagination to be a painter because you can invent things. But in photography everything is so ordinary; it takes a lot of looking before you learn to see the extraordinary."

- David Bailey

Capítulo 2

Identificação de estruturas

Neste capítulo, será abordado o tema identificação de estruturas em imagens digitais. Primeiramente, o problema da identificação será descrito e inserido dentro do contexto de Visão Computacional. Serão definidas as etapas de processamento envolvidas na identificação automática de estruturas. Apresentar-se-á, ainda, neste item, uma classificação das estratégias para identificação automática de estruturas. A seguir, será feita uma revisão de trabalhos de identificação automática na área de imagens médicas. Por fim, será feita uma discussão sobre a utilização de métodos baseados em múltiplas escalas para identificação de estruturas em imagens médicas e como o presente trabalho pretende contribuir para a área de identificação de estruturas, utilizando o conceito de espaço de escalas.

2.1. Identificação de estruturas em imagens digitais

2.1.1. Colocação do problema

A identificação de estruturas e padrões em uma dada cena é uma capacidade humana reconhecidamente bem desenvolvida, que permite perceber e entender o mundo através da visão e, desta forma, nele atuar. O Reconhecimento e a Identificação Automáticas de Estruturas constituem campos da disciplina de Visão Computacional. O principal objetivo dessa disciplina é simular o processo de visão humana através da percepção e compreensão

dos dados de imagens digitais (Sonka, 1998). O reconhecimento de estruturas é uma tarefa difícil, porque vários fatores influem na sua execução. Esses fatores podem incluir restrições nas formas permitidas, na semântica do contexto da cena e na informação presente na própria imagem (Suetens, 1992). Uma vez efetuado o reconhecimento das estruturas, o passo seguinte na interpretação de uma cena, consiste na identificação de um ou mais objetos de interesse particular em meio ao conjunto de objetos reconhecidos.

Cabe, neste ponto, uma distinção entre os conceitos de reconhecimento e identificação de estruturas. Existem muitas definições na literatura para reconhecimento (ou detecção) de estruturas. Utilizaremos aqui uma definição simples, dada por Suetens *et al.* (1992):

O reconhecimento (ou detecção) de estruturas é a tarefa de encontrar e marcar as partes de uma imagem digital que correspondem a objetos na cena.

A partir do reconhecimento das estruturas de uma imagem, o próximo passo é identificar uma instância de uma estrutura particular. A definição de identificação de objetos não é precisa e, dependendo da aplicação, pode ser confundida com o conceito de reconhecimento. Neste trabalho, a identificação é definida pela autora como:

A identificação de uma estrutura particular consiste em discriminar, dentre as estruturas reconhecidas, aquela que corresponde ao objeto procurado.

A execução de tarefas de visão por seres humanos envolve muitos processos que, em geral, são realizados de forma inconsciente e que, por isso, são chamados de *baixo nível*, como a eliminação do ruído, a compensação de possíveis artefatos de aquisição, a adaptação à luz ambiente, a percepção das bordas dos objetos. Além desses processos básicos, a tarefa de identificação envolve julgamento e, em geral, um enorme conhecimento do domínio do problema (Gregory, 1990). No domínio de imagens médicas, isso inclui o conhecimento do padrão de geometria, posição, intensidade de nível de cinza e relação espacial com as outras estruturas da imagem, que se espera encontrar em condições normais, e dos desvios desse padrão, que caracterizam condições patológicas. A perfeita integração dessas habilidades de

alto nível ao processo de visão de baixo nível, realizada pelo cérebro, é a responsável pela notável habilidade visual dos seres humanos.

Para ilustrar os conceitos expostos e as etapas envolvidas na identificação de uma estrutura, considere-se o exemplo da imagem apresentada na figura 2.1, na qual é apresentado um corte transversal da região do tórax, em uma imagem de Tomografia Computadorizada por raios X.



Figura 2.1. Corte transversal de tórax – imagem de tomografia computadorizada por raios X. A seta branca aponta para o ramo da aorta. (Imagem adquirida no Serviço de Radiologia da Divisão de Diagnóstico por Imagens – Instituto do Coração – HCFMUSP)

Supondo que a imagem seja analisada para verificar possíveis problemas na aorta (identificada na figura 2.1 pela seta branca), a tarefa do profissional de saúde consiste em: (a) identificar a aorta na imagem e (b) avaliar o estado de normalidade/anormalidade dessa aorta. Para realizar essa tarefa, são necessários os seguintes passos:

- localizar na imagem a região que corresponde ao tórax. Supondo que o observador tenha conhecimento de que, em uma imagem desse tipo, a região procurada tem forma elíptica e apresenta tons de cinza mais claros que o fundo, seria fácil localizar o tórax em contraste com o fundo preto sem estruturas, à exceção da maca sob o paciente;
- reconhecer as estruturas na região interna do tórax que correspondem a órgãos: podem ser visualizados os pulmões, a região apical do coração, o fígado, a coluna e a aorta. Para realizar essa operação, o observador deve ter conhecimento sobre as formas, tamanhos, intensidades e posições relativas esperadas de cada uma

dessas estruturas em uma imagem do tipo analisado. Este passo e o anterior constituem a etapa de reconhecimento de objetos na imagem;

- dentre as estruturas reconhecidas, deve-se identificar a aorta. Para isso, o observador deve ter a informação de que procura por uma estrutura de forma arredondada, que deve estar localizada na parte inferior da região interna do tórax, próxima ao coração e à coluna;
- após a identificação da estrutura desejada, foca-se a atenção para o objeto de interesse. A partir desse momento, detalhes dessa estrutura, como bordas e intensidade, são observados com maior atenção. Essas características vão permitir avaliar a condição do órgão ou estrutura, o que depende de alguns fatores:

tamanho: para avaliá-lo, o observador precisa saber estimar a faixa de tamanhos esperados, que depende de vários fatores, como sexo, idade e peso. O tamanho esperado também depende da resolução da imagem analisada;

forma: neste caso, é necessário saber que a forma dada pela intensidade média da estrutura, em imagens como a apresentada, está relacionada com o fluxo sanguíneo. Variações na forma indicam, então, variações no fluxo que podem ser causadas, por exemplo, por um estreitamento da aorta nessa região;

posição: o observador espera que o órgão procurado se encontre em uma determinada região do tórax. Variações na posição podem indicar algum distúrbio ou anomalia.

contexto: a análise deve considerar a sua relação com os demais órgãos reconhecidos na imagem.

Esse exemplo deixa claro que a capacidade dos seres humanos em diferentes tarefas visuais precisa ser desenvolvida através de aprendizado formal ou informal. Uma pessoa não treinada em análise de imagens médicas certamente experimentaria muitas dificuldades na execução da tarefa proposta.

2.1.2. Identificação automática

A disciplina de Visão Computacional pesquisa formas de se realizar automaticamente tarefas visuais como a descrita no item anterior. Em aplicações médicas, o objetivo final é obter não apenas conclusões qualitativas, como “*a aorta apresenta dimensão aumentada*”, mas também resultados quantitativos, que permitam avaliar objetivamente as variações em relação aos padrões normais. Por exemplo, “*o diâmetro da aorta apresenta um aumento de 25% em relação ao padrão de normalidade para as faixas de idade e sexo do paciente*”.

Para que seja possível obter tais resultados, é necessário **identificar** o objeto de interesse e, após a identificação, **analisá-lo**. A identificação automática envolve um grande número de operações a partir dos dados originais de aquisição: esses dados precisam ser processados para que o corte tomográfico seja formado – supondo-se imagens tomográficas - o que inclui filtragem e algoritmo de reconstrução. Uma vez obtido o corte, são necessárias transformações na imagem, de forma a tornar os dados mais adequados à identificação, o que se obtém através de processos como os algoritmos de detecção de bordas e segmentação. A seguir, são necessários procedimentos de alto nível, que envolvem explicitação de conhecimento *a priori*, para determinar a estrutura que corresponde à procurada e, na etapa final, analisá-la.

Com o objetivo de simplificar a compreensão das etapas envolvidas na identificação automática de estruturas, elas são divididas em níveis. Alguns autores propõem uma divisão em 2 níveis: baixo e alto (Ballard, 1982; Sonka, 1998), enquanto outros utilizam três níveis de processamento: baixo, médio e alto (Gonzales, 2000; Niessen, 1997). Neste texto, será utilizado o modelo de três níveis.

A figura 2.2 apresenta um diagrama no qual as etapas envolvidas na identificação e a divisão, em três níveis, são apresentadas.

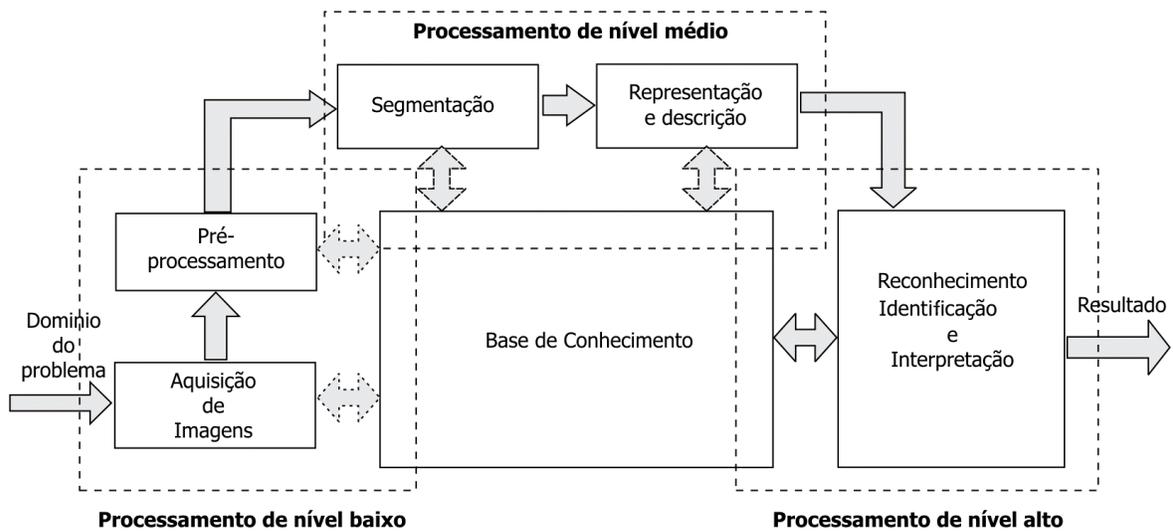


Figura 2.2. Etapas de processamento para reconhecimento e interpretação de estruturas em imagens digitais. Figura adaptada de Gonzales (2000).

O processamento de baixo nível trata de funções equivalentes às reações visuais automáticas humanas que, normalmente, requerem pouco ou nenhum conhecimento a respeito do conteúdo da imagem (Gonzales, 2000; Sonka, 1998). É principalmente, ou quase totalmente, baseado nos dados intrínsecos da imagem, sem inclusão de informações *a priori*. Inclui atividades como o próprio processo de formação das imagens, filtragens para redução de ruído e correção de artefatos de aquisição. Além disso, são efetuados processamentos que permitem restringir a enorme quantidade de dados presentes na imagem original e obter imagens paramétricas que descrevam informações relevantes da imagem. Exemplos de parâmetros relevantes são contraste local, textura, curvatura e movimento.

No processamento de nível intermediário são efetuadas as tarefas de extração e caracterização de componentes nas imagens resultantes do processo de baixo nível (Gonzales, 2000). Esta etapa inclui atividades como segmentação, representação e descrição das informações da imagem por meio de modelos. Para os autores que não utilizam este nível de classificação, estas funções são geralmente definidas como de baixo nível (Ballard, 1982; Sonka 1998). Os autores que incluem o nível intermediário ressaltam que a diferença com o processamento de baixo nível é que, com base em algumas restrições, pode-se selecionar ou destacar informações relevantes para uma aplicação particular e formalizá-las por meio de modelos que incluam alguma informação *a priori* sobre o domínio da

aplicação, facilitando as tarefas posteriores de alto nível (Niessen, 1997). Além disso, o resultado desta etapa de processamento gera não mais imagens, mas representações de imagens.

O processamento de alto nível é baseado em conhecimento, objetivos e estratégias de como melhor atingir os objetivos propostos. Utilizando conhecimento prévio sobre a estrutura da imagem, os dados são sistematicamente avaliados. Hipóteses são confirmadas ou rejeitadas pelos dados. Nas rotinas de processamento de alto nível, as informações devem estar organizadas de forma a facilitar buscas rápidas. A diferença entre a visão de alto nível e a visão de nível intermediário é a utilização explícita de conhecimento sobre o contexto da imagem sob análise.

2.1.3. Níveis de representação de dados

O objetivo da identificação automática de estruturas é obter resultados similares àqueles obtidos por seres humanos. Para atingir esse objetivo, é necessário encarar um grande desafio: mimetizar ou reinventar, utilizando hardware genérico ou específico, as habilidades mais básicas e algumas das mais refinadas do sistema visual humano, que são realizadas por unidades funcionais altamente especializadas, constantemente aprimoradas ao longo de nossa evolução.

Um exemplo freqüentemente encontrado nos textos para ilustrar o grau de dificuldade da tarefa é apresentado na figura 2.3. Nessa imagem, é utilizada uma representação de dados na qual a intensidade em cada posição da imagem é dada pelo valor do eixo vertical. A mesma imagem, desta vez na representação usual de intensidades (tons de cinza) em função da posição, é apresentada na figura 2.4. Ambas representações contêm exatamente as mesmas informações, porém qualquer pessoa teria muita dificuldade em reconhecer o rosto na figura 2.3 (Ballard, 1982; Sonka, 1998).

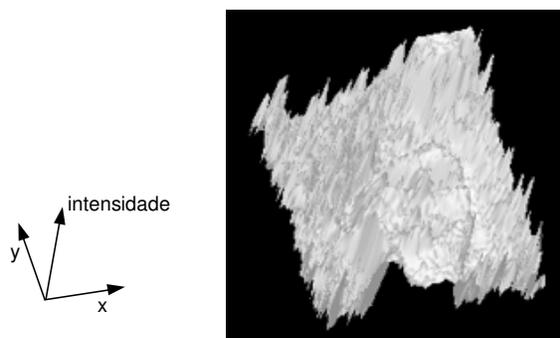


Figura 2.3. Imagem na qual o valor de intensidade do pixel é dado pela altura da superfície nesse ponto. Figura obtida a partir da imagem 2.4, pela aplicação de uma transformação utilizando o software AVS^{2.1}.



Figura 2.4. A mesma imagem de 2.3, com representação em níveis de cinza.

No processo de identificação automática, o sistema computacional possui, como dados iniciais, um conjunto de números (o *array* de bytes), que equivale à observação de uma imagem como a apresentada na figura 2.3. Enquanto o computador é muito eficiente para processar localmente partes da imagem, é muito difícil estabelecer métodos para que ele exiba conhecimento global. Isso ocorre porque existe uma distância enorme entre a imagem original e os modelos que explicam, descrevem ou abstraem as informações contidas nessa imagem (Ballard, 1982). Para que esse conhecimento possa ser utilizado pelo sistema computacional, é necessário que sejam usadas representações poderosas e compatíveis com os sistemas automáticos. Na transição dos dados de imagem a partir do *array* inicial de bytes até o modelo, a informação desses dados vai se tornando mais concentrada, e o conhecimento semântico sobre a interpretação da imagem, armazenado em

^{2.1} AVS: Advanced Visual System. Ambiente para visualização interativa e processamento de imagens.

uma base de conhecimento, é utilizado de forma progressiva, à medida que o nível de processamento aumenta (Sonka, 1998).

As representações de dados de imagens podem ser classificadas em quatro níveis (Ballard, 1982). Essas quatro representações incluem desde sinais com um nível muito baixo de abstração (o *array* de bytes inicial) até descrições que podem ser percebidas por humanos. O fluxo de informações entre os níveis pode ser bi-direcional e, para aplicações específicas, alguns níveis podem ser omitidos (Sonka, 1998). Os quatro níveis são:

- **Imagens generalizadas:** este nível é formado pelas imagens contendo os dados originais: *arrays* contendo dados da intensidade dos pixels. Também compõem este grupo imagens produzidas como resultado de processamentos de baixo nível, utilizadas para destacar aspectos da imagem que são importantes para etapas posteriores.
- **Imagens segmentadas:** são formadas a partir de imagens generalizadas, pelo agrupamento de seus elementos em conjuntos que idealmente pertencem ao mesmo objeto na cena.
- **Representações geométricas:** são utilizadas para capturar o conhecimento de formas 2D e 3D. A caracterização de formas é uma tarefa muito difícil, porém igualmente importante. A representação de estruturas geométricas constitui um mecanismo extremamente útil de codificação de conhecimento adquirido sobre um determinado domínio.
- **Modelos relacionais:** são agrupamentos complexos de representações, usados para dar suporte a processamento com alto nível de elaboração. Eles permitem o tratamento mais eficiente de dados e com níveis mais altos de abstração. O processamento de alto nível freqüentemente utiliza conhecimento *a priori* e modelos adquiridos anteriormente ao início do processamento. O processamento típico consiste em construir representações que serão comparadas com os dados experimentais.

A relação entre os níveis de representação de dados e as etapas de processamento é imediata, pois cada nível de representação é adequado ao nível de processamento equivalente, conforme ilustrado na figura 2.5. Esta figura apresenta uma versão simplista, porém didática, do aumento do nível de abstração da representação em cada etapa de

processamento. Em sistemas reais, cada etapa de processamento pode utilizar e gerar dados de mais de uma única representação.

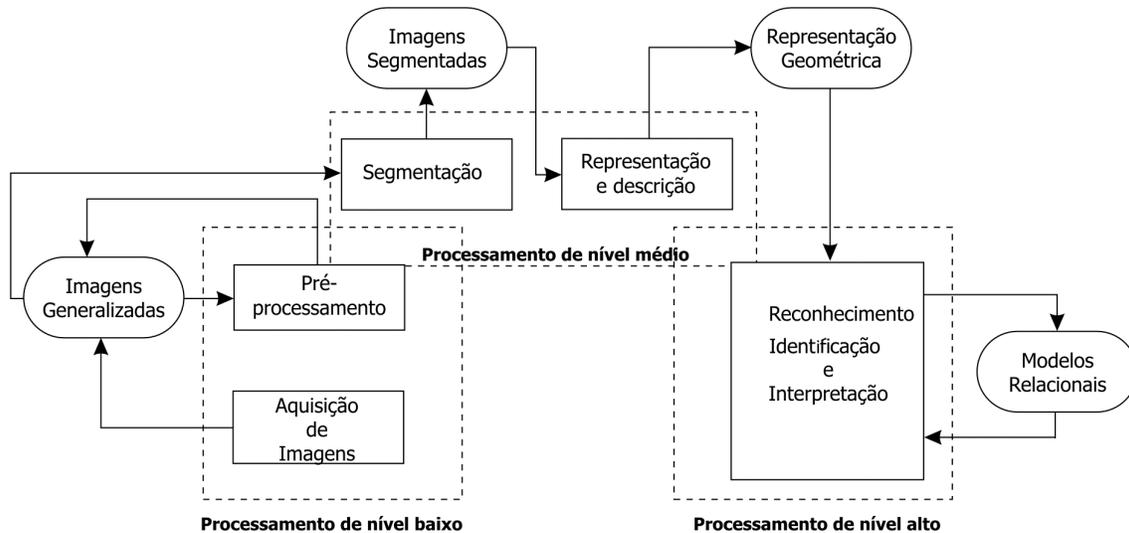


Figura 2.5. Relação entre os níveis de representação e os níveis de processamento. Figura adaptada, a partir da figura 2.2, para ilustrar a relação entre os níveis de processamento (Gonzales, 2000) e a classificação de níveis de imagens (Ballard, 1982).

Estratégias para identificação de objetos

Para a realização da tarefa de identificação de objetos, uma etapa fundamental é o estabelecimento de modelos, ou descrições gerais, dos objetos procurados. O modelo tipicamente inclui informações sobre forma, textura e conhecimento contextual a respeito da ocorrência do objeto na cena.

A utilização de métodos simples, que se baseiam apenas em informações contidas nos dados da própria imagem, em geral, não produz resultados satisfatórios. Ou seja, as informações intrínsecas da imagem não são capazes de caracterizar estruturas presentes em objetos reais (Suetens *et al.*, 1992). Procedimentos efetivos para identificação de estruturas devem incorporar conhecimentos do modelo ou do contexto.

Suetens *et al.* (1992) classificaram as estratégias computacionais para implementar esses processamentos de acordo com duas características principais: sua adequabilidade para dados de imagens complexos e sua adequabilidade para modelos complexos. Para os

autores, a **complexidade dos dados** corresponde à razão sinal-ruído na imagem. Segundo essa abordagem, uma imagem com ambigüidade semântica corresponde a dados ruidosos e complexos. Imagens caracterizadas por alto ruído, baixa resolução, ou com presença de artefatos necessitam de métodos especialmente projetados para extração das instâncias do modelo. Da mesma forma, para imagens que facilmente resultam em instâncias falsas, são necessários métodos para distinguir os objetos corretos dos falsos. A **complexidade do modelo** é dada pelo nível de detalhe nas estruturas de dados e nas técnicas necessárias para determinar a forma de organização dos mesmos. Por exemplo, se o modelo for definido por critérios simples como um único padrão de forma, ou a otimização de uma única função, não é necessária a utilização de outras informações contextuais. Se, por outro lado, muitos componentes de modelos simples precisarem ser aglutinados ou relacionados hierarquicamente para estabelecer a existência da instância de modelo desejada, estruturas de dados complexas e técnicas não triviais de busca podem ser necessárias.

Com base nessas duas características, as estratégias foram divididas em quatro grupos, que são apresentados de forma esquemática na figura 2.6.

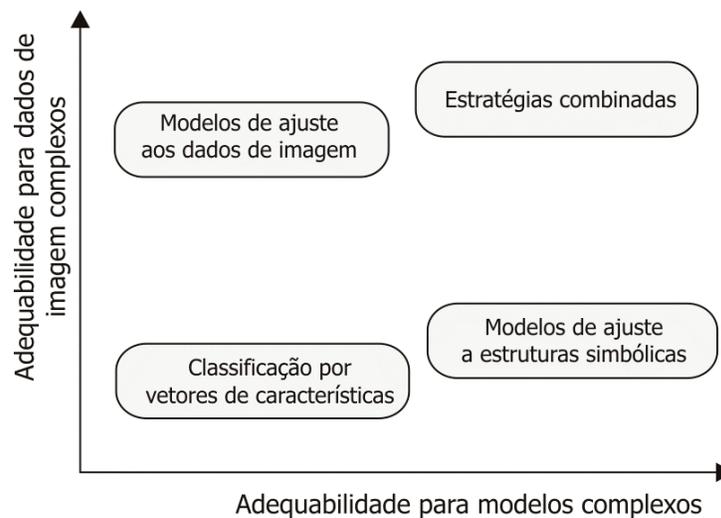


Figura 2.6. Espaço de classificação para estratégias de reconhecimento de estruturas proposto por Suetens *et al.* (1992).

A seguir, apresenta-se uma breve descrição de cada um dos tipos de estratégia (Suetens *et al.* 1992).

Classificação por vetores de características

Os objetos de uma imagem são modelados como vetores de características, cada um dos quais corresponde a pontos no espaço multidimensional de características. As características consideradas neste caso são obtidas diretamente da imagem. Exemplos de características incluem intensidade, cor, área, perímetro, grau de compactação e número de buracos na estrutura. Para utilizar esta estratégia, é necessário selecionar as características relevantes do objeto a ser modelado, determinar uma forma de medi-las e definir um critério para distinguir o objeto desejado dos outros objetos presentes na imagem, baseado nessas características. Uma vez definido o espaço de características, ele é dividido em regiões que correspondem a modelos de objetos diferentes. Esse procedimento permite a associação de novos objetos às classes de objetos conhecidos. As fronteiras de decisão normalmente são definidas em uma fase de treinamento, a partir de uma amostra estatisticamente significativa dos objetos em questão.

Modelos de ajuste aos dados das imagens

Aqui são definidos modelos que são ajustados diretamente aos dados das imagens. Métodos deste tipo incorporam mais conhecimento sobre o domínio do problema do que os da estratégia anterior. Um exemplo simples é a busca por estruturas circulares, para tentar encontrar imagens de artérias como a aorta da figura 2.1. Essa estratégia costuma ser dividida em duas categorias: ajuste rígido e ajuste flexível. O casamento de padrões é o precursor das estratégias de ajuste rígido. Um padrão representa o objeto como uma curva ou uma imagem. Uma métrica ou medida de similaridade, que reflita o grau de semelhança dos dados da imagem ao padrão, é utilizada para encontrar o padrão ótimo. A métrica mais simples quantifica a similaridade entre duas imagens por correlação, que pode ser o quadrado das diferenças entre os pixels, correlação estatística, entre outras (Ballard, 1982). Os métodos de ajuste flexível, por sua vez, usam, como o próprio nome indica, modelos flexíveis especificados por um conjunto de restrições genéricas dos objetos, como suavidade, curvatura, grau de compactação, simetria, homogeneidade. O ajuste do modelo à imagem é normalmente feito por uma função, e a escolha é feita pela minimização do valor

dessa função. Programação dinâmica é um exemplo deste tipo de método (Suetens *et al.*, 1992).

Modelos de ajuste a estruturas simbólicas

Esta estratégia atua sobre um conjunto de características que tenham sido obtidas, de forma confiável, a partir dos dados da imagem. As características podem ser regiões segmentadas da imagem, marcações produzidas por uma etapa de casamento de padrões. As principais categorias desta estratégia são: casamento de grafos e ajuste de modelos. No casamento de grafos, os objetos são modelados como estruturas relacionais ou primitivas de grafos. Os nós são os componentes do objeto ou cena e os arcos indicam as relações entre eles. Marcas são obtidas a partir da busca pelo ajuste ótimo dos grafos referência e do grafo obtido a partir dos dados da imagem. Alguma heurística pode ser utilizada para diminuir a árvore e reduzir o tempo computacional necessário. Esta operação, entretanto, pode introduzir o risco de que seja encontrada uma solução que não seja a ótima. No ajuste de modelo hierárquico, a redução do espaço de busca é obtida através de uma abordagem hierárquica: são feitos casamentos parciais, através do uso de modelos intermediários, e então, refinando-os.

Estratégias combinadas

Nesta estratégia, os métodos utilizam explicitamente técnicas de modelagem hierárquica para limitar a busca de candidatos ao ajuste. Uma seqüência de modelos intermediários, que são progressivamente mais complexos, é usada para encontrar e refinar os casamentos parciais. Os estados intermediários criam um contexto para a análise subsequente.

2.2. Aplicações médicas

Em 1895 Röntgen descobriu os raios X e, a partir dessa descoberta, passou a ser possível visualizar estruturas internas do corpo humano. Essa possibilidade revolucionaria a área de diagnósticos em Medicina. No decorrer do último século, novas formas de obter informação visual do interior do corpo humano foram desenvolvidas. Atualmente, pode-se obter excelentes informações anatômicas através das técnicas de Tomografia

Computadorizada por raios X e Ressonância Magnética, ou ainda informações funcionais utilizando técnicas como Ultra-sonografia, Medicina Nuclear ou Ressonância Magnética Funcional.

Com a disseminação do uso de imagens médicas para fins diagnósticos, aliada ao rápido desenvolvimento de técnicas computacionais para análise de imagens digitais, começaram a ser feitos grandes esforços no sentido de automatizar as tarefas de análise, interpretação e diagnóstico de imagens médicas. As primeiras experiências em análise computacional de imagens por raios X surgiram na década de 60 (van Ginneken *et al.*, 2001) e, na década de 70, foram publicados os primeiros artigos para detecção automática de anormalidades em imagens por raios X (Becker 1964 *et al.*^{2.2} *apud* van Ginneken 2001 p. 1228, Meyers *et al.*^{2.3} 1964 *apud* van Ginneken 2001 p. 1228). A partir daí, surgiram pesquisas por métodos automáticos de análise em todas as modalidades de imagens médicas. Os primeiros trabalhos na área eram muito otimistas a respeito da possibilidade de diagnósticos gerados apenas por computadores (van Ginneken *et al.*, 2001), entretanto essa expectativa inicial não foi atingida. Após três décadas de pesquisas, existe um consenso que o foco das pesquisas na área deve ser em disponibilizar a informação relevante para o médico, através de sistemas desenvolvidos para suporte à decisão, ao invés de tentar realizar o diagnóstico utilizando apenas o computador (Engle^{2.4} 1992 *apud* van Ginneken, 2001, p. 1228). Inúmeras pesquisas na área de diagnóstico auxiliado por computador (CAD - *computer-assisted diagnosis*) têm sido relatadas nos últimos anos. Algumas delas serão apresentadas no item 2.2.2.

Um dos problemas mais importantes envolvidos no desenvolvimento de sistemas de apoio à decisão clínica em aplicações que envolvem a visualização e análise de imagens é a identificação de estruturas. No contexto de imagens médicas, o conceito de identificação,

^{2.2} Becker, H.; Nettleton, W.; Meyers, P.; Sweeney, J.; Nice Jr, C. **Digital computer determination of a medical diagnostic index directly from chest X-ray images.** IEEE Transactions on Biomedical Engineering, v. BME-11, p.67-72, 1964.

^{2.3} Meyers, P.; Nice Jr., C. Becker, H.; Nettleton, W.; Sweeney, J.; Meckstroth, G. **Automated computer analysis of radiographic images.** Radiology, v. 83, p.1029-1034, 1964.

^{2.4} Engle, R. **Attempts to use computers as diagnostic aids in medical decision making: a thirty years experience.** Perspectives Biol. Med., v. 35, p.207-217, 1992.

como definido no item 2.1.1, abrange a discriminação de um órgão em particular, em detrimento de outros órgãos ou a discriminação normalidade/anormalidade para um determinado órgão baseada nos atributos da imagem.

Na seção a seguir, será feita uma revisão da utilização de informações *a priori* em aplicações de segmentação e identificação de imagens médicas. A seguir será dada uma breve introdução ao problema de identificação de estruturas em imagens médicas, com apresentação de algumas aplicações descritas na literatura. As revisões feitas aqui não pretendem ser extensivas, com todas as possíveis áreas de aplicação clínica e todas as possíveis técnicas aplicadas. Uma revisão tão abrangente foge ao escopo deste trabalho. O objetivo principal aqui é exemplificar os conceitos expostos neste capítulo em aplicações médicas, e mostrar as abordagens que têm sido utilizadas para esse fim.

2.2.1. Utilização de informações *a priori* para identificação de estruturas em processamento de imagens médicas

A utilização de imagens médicas como auxiliar ao diagnóstico médico já ocorre há décadas. Entretanto, a caracterização de tecidos e órgãos ainda não é precisa em termos computacionais. Embora os clínicos sejam capazes de encontrar e classificar os órgãos com facilidade e precisão, não existe ainda um meio de transpor essa técnica para ambientes computacionais. Na literatura encontram-se vários trabalhos que visam caracterizar o conhecimento sobre um determinado tipo de órgão presente em uma modalidade de imagem médica, de tal forma a auxiliar o processamento automático dessa imagem.

Vilanova *et al.* (2000) apresentaram uma proposta de aproximação de órgãos tubulares por estruturas cilíndricas para visualização em endoscopia virtual. Kim *et al.* (2000) utilizaram informação de forma para discriminar estruturas de células sanguíneas e possíveis anormalidades. Rugeri e Pajaro (2002) usaram o formato das células da córnea em um sistema para classificação de camadas da córnea em imagens de microscopia confocal. Park *et al.* (2000) incorporaram informações anatômicas sobre forma e relação com outras estruturas anatômicas para extração automática de bordas pulmonares em imagens de raios X. Lin *et al.* (2003) utilizaram conhecimento de forma para segmentação de imagens em ultrassonografia.

Karam *et al.* (2003) utilizaram informações de textura para caracterização de imagens de tomografia computadorizada de pulmão em um sistema para recuperação de imagens baseado em conteúdo. Kunz *et al.* (2004) usaram informações de textura e forma para extração e classificação de características em imagens de ressonância magnética para planejamento de terapia de prótons em tumores nos olhos.

Kobashi e Shapiro (1995) acrescentaram que existem informações contextuais importantes que podem e devem ser utilizadas na identificação de uma estrutura particular, como a localização espacial do órgão na imagem (em termos de posição horizontal e vertical) e a posição relativa em relação a outros órgãos. Os autores defenderam, ainda, a utilização de um número maior de características para identificação, com atribuição de pesos menores para cada uma das características em detrimento de uma abordagem que utilize um número mais reduzido de características, cada uma delas com um peso maior.

Kobashi e Shapiro (1995) indicaram, ainda, que uma grande dificuldade na utilização de informação *a priori* de formas, é caracterizar geometricamente os órgãos, pois existem poucas invariantes de forma na caracterização das estruturas anatômicas humanas. Ao contrário dos objetos rígidos de outras aplicações de visão computacional, a maioria dos órgãos humanos apresenta poucas invariantes calculáveis e estáveis. Exceções a essa regra são, por exemplo, globo ocular e seções da aorta, cuja forma é quase perfeitamente circular. Del Bimbo e Pala (1999), em um trabalho sobre recuperação de imagens em bancos de dados, afirmaram que existe uma enorme dificuldade em definir uma medida de similaridade para agrupar formas que simulem este conceito na percepção humana. Isso decorre da dificuldade de se estabelecer um modelo matemático adequado que reflita a maneira como os humanos percebem as formas e a similaridade entre elas. Os autores propuseram a utilização de um critério de similaridade que usa um conjunto de imagens em escalas distintas.

2.2.2. Identificação de estruturas aplicada a imagens médicas

A identificação de estruturas é uma etapa fundamental para a realização de diversos procedimentos na área médica, como: visualização e planejamento cirúrgico (Ruggeri e Pajaro, 2002; Bartolini *et al.*, 2004; Zrimec e Sammut, 1997), planejamento para

procedimentos de radioterapia (Kobashi e Shapiro, 1995), identificação de tumores, má-formação e disfunções (Verma e Zakos, 2001; Ogiela e Tadeusiewicz, 2000; Cheng *et al.*, 2003; Goodenday *et al.*, 1997; Frangi *et al.*, 1999; Keserci e Yoshida, 2002; Fang *et al.*, 2002; van Ginneken *et al.*, 2001; Zwiggelhaar *et al.*, 1999; Liu *et al.*, 2001; Costa e Moura, 1996), classificação de órgãos, tecidos e células (Rivière *et al.*, 2002; Cocosco *et al.*, 2003; Thies *et al.*, 2004; Chalopin *et al.*, 1998; Krissian *et al.*, 2000) e recuperação de casos semelhantes em bases de imagens baseada em conteúdo (Dy *et al.*, 2003).

As imagens médicas têm algumas características específicas. Essas imagens frequentemente são obtidas a partir de alguma forma de energia que interage com as estruturas; isto significa que as suas superfícies não são opacas. As características a serem detectadas nas imagens podem ser pequenas e sutis, algumas vezes caracterizadas apenas por mudanças extremamente suaves no nível de cinza. Por outro lado, em muitas aplicações, existe uma quantidade significativa de informação *a priori* da anatomia humana (Nevatia, 1982).

A especificidade das imagens médicas torna a sua análise e interpretação uma das aplicações mais difíceis e importantes das áreas de visão computacional e reconhecimento de padrões (Verma e Zakos, 2001). Uma grande dificuldade em todo o processo é a criação de modelos eficientes que representem as estruturas biológicas. Essa modelagem normalmente inclui estruturas com formas bastante complexas, que não são facilmente descritas computacionalmente. Além disso, essas estruturas normalmente variam em relação à forma ou tamanho em uma população. O modelo deve ser capaz de lidar com a diversidade existente em estruturas normais e acomodar as formas anormais também, neste caso identificando-as como tal.

Devido à complexidade das aplicações, a maior parte das soluções para identificação adota estratégias combinadas. As soluções envolvem, em sua maioria, as três etapas de processamento descritas no item 2.1.2. Aplica-se, primeiramente, algum tipo de pré-processamento na imagem, de forma a minimizar os efeitos de ruído ou artefatos de aquisição, ou ainda realçar características que auxiliem as etapas posteriores de processamento. O tipo de processamento, nesta etapa, é bastante dependente da modalidade

da imagem. A etapa seguinte, de segmentação, ainda apresenta dependência em relação à modalidade, mas aqui o tipo de estrutura procurada já passa a dirigir fortemente o processo. A partir daí, na segunda fase do processamento de nível médio - a representação e descrição - e na fase de processamento de nível superior, a abordagem é focada na estrutura procurada.

2.2.3. Algumas aplicações

Os primeiros trabalhos na área de identificação de estruturas em imagens médicas foram em radiografias de tórax. Em seu artigo de revisão sobre CAD em radiografia de tórax, van Ginneken *et al.* (2001) afirmaram que a detecção automática de nódulos no pulmão é o problema mais estudado em análise computacional de radiografias. Os métodos para a detecção de nódulos normalmente são divididos em duas etapas principais: na primeira, os nódulos são detectados e na segunda, é eliminado o maior número possível de falsos positivos, ou seja, nódulos benignos identificados erroneamente como malignos. Muitos métodos incluem ambas as etapas, mas o foco é sempre em uma delas. Os nódulos candidatos são detectados, após uma etapa de pré-processamento, usando casamento de padrões, ou mesmo métodos simples como limiarização. Para a eliminação de falsos positivos, algumas características específicas são detectadas para cada nódulo candidato. Normalmente, são utilizadas características “clássicas” que são descritas em textos de processamento de imagens e, a seguir, classificadores – geralmente simples – são utilizados para a identificação dos falsos positivos. Keserci e Yoshida (2002) utilizaram uma abordagem em múltiplas escalas para refinar a identificação de falsos positivos, através da aplicação de um modelo de *wavelet snake* para detecção de características da imagem. Dy *et al.* (2003) apresentaram uma metodologia para seleção automática de características ótimas para discriminação de patologias do pulmão para aplicação em Sistema de Recuperação Baseado em Conteúdo da Imagem (CBIR – *Content Based Image Retrieval*).

Em sua revisão, van Ginneken *et al.* (2001) destacaram que uma aplicação na qual os sistemas CAD têm se mostrado bastante efetivos é a mamografia. Um sistema de apoio ao diagnóstico clínico que identifique e classifique padrões de microcalcificações em mamogramas pode ser muito útil para o radiologista. Cheng *et al.* (2003) fizeram uma

revisão dos métodos automáticos para esse fim. Segundo os autores, a tarefa pode ser dividida em duas grandes etapas. A primeira etapa consiste na detecção de microcalcificações. Os autores analisaram algumas estratégias para essa etapa do processamento: (1) detecção baseada nas características intrínsecas da imagem, (2) detecção baseada em características estatísticas de textura, (3) detecção baseada em características de textura em múltiplas escalas, (4) detecção baseada em características de dimensão fractal e (5) detecção de agrupamentos de microcalcificações. Um exemplo de detecção de microcalcificações foi apresentado no trabalho de Zwiggelaar *et al.* (1999), que se concentra na detecção de lesões especulares. Os autores desenvolveram modelos estatísticos para descrição e detecção dessas estruturas e obtiveram bons resultados em seus experimentos. A partir da identificação das microcalcificações, o próximo passo é a distinção entre tumores malignos e benignos. Essa é uma tarefa complexa, devido à grande variação de forma, tamanho e composição da mama. Verma e Zakos (2001) desenvolveram um sistema baseado em Redes Neurais Difusas para essa distinção. Uma análise de técnicas de extração de características da imagem determinou que a melhor combinação para distinção dos padrões de tumores malignos e tumores benignos é a utilização de três características combinadas, como por exemplo, entropia, desvio padrão e o número de pixels. Liu *et al.* (2001) utilizaram *wavelets* para a detecção de lesões especulares em mamogramas, determinando em diversas escalas as características a serem utilizadas para a identificação. Costa e Moura (1996) apresentaram um método automático de detecção e classificação de lesões, que faz uso do filtro de novidade de Kohonen. A classificação automática é obtida a partir da análise do perfil médio da lesão extraída.

Um método para identificação de lesões morfológicas em imagens de raios X que facilita o diagnóstico de câncer pancreático foi apresentado por Ogiela e Tadeusiewicz (2000). O método utiliza gramáticas para identificar patologias nos condutos pancreáticos, que podem ser caracterizadas por variações morfológicas. Fang *et al.* (2002) desenvolveram uma metodologia para a identificação e contagem de células tumorais, propondo um sistema que gera regras para extração de características da imagem otimizadas para esse fim.

Outra área para a qual a identificação de estruturas representa uma etapa muito importante é a visualização para planejamento cirúrgico. Bartolini *et al.* (2004) apresentaram um método para identificação dos condutos da medula em imagens de raios X, para planejamento cirúrgico de implante de prótese femoral. Para isso, eles desenvolveram um modelo geométrico dos condutos, que é utilizado na etapa de casamento de estruturas para identificação. Ruggeri e Pajaro (2002) descreveram uma metodologia utilizando uma rede neural para identificação de camadas da córnea em imagens de microscopia confocal, que classifica as estruturas de acordo com características de forma das células de cada camada. A identificação correta é uma etapa importante para o planejamento de cirurgias de correção a laser.

A identificação com fins de visualização para planejamento radioterápico também é descrita na literatura. Kunz *et al.* (2004) utilizaram uma estratégia para planejamento de radioterapia em tumores de retina, que envolve a identificação ocular pelo casamento de características da imagem analisada com as de imagens de um banco de dados. Kobashi e Shapiro (1995) desenvolveram um trabalho para identificação de órgãos abdominais em imagens de CT, como uma etapa no planejamento de tratamento radioterápico. A identificação é efetuada por um sistema baseado em conhecimento. A base de conhecimento inclui informações anatômicas, informações sobre o processo de formação das imagens e informações sobre os efeitos dos operadores aplicados para extração dos órgãos.

Nas áreas de visualização da anatomia e análise da fisiologia cerebral também existem algumas contribuições. Rivière *et al.* (2002) desenvolveram um sistema para identificação automática dos principais sulcos do córtex de cérebro humano em imagens de ressonância magnética. A identificação do sulco é uma parte do processo de fusão de imagens com atlas deformáveis. Para a identificação, os autores utilizaram uma rede neural para o ajuste com uma representação abstrata das estruturas na imagem, por meio de grafos. Cocosco *et al.* (2003) descreveram um sistema para identificação de estruturas cerebrais em imagens tri-dimensionais de ressonância magnética, baseado em um classificador que utiliza amostras geradas previamente por mapas de probabilidade para os diversos tecidos. Fidrich

e Thirion (1994) apresentaram um trabalho para extração de curvas utilizando espaço de escalas, que permitiu a visualização de superfície cerebral.

Na área cardíaca, Goodenway *et al.* (1997) utilizaram uma rede neural não supervisionada para avaliar a perfusão miocárdica em imagens de cintilografia de perfusão. A rede foi construída de forma a reproduzir a relação entre a retina humana (que constitui o segmento visual) e o cérebro (segmento associativo), e possui 4 camadas: (1) a camada mais baixa, que é a camada sensorial; duas camadas intermediárias, (2) camada de vetores de características e (3) camada de agregação de características; e (4) uma camada superior associativa. Chalopin *et al.* (1998) desenvolveram um método para identificação automática da árvore coronariana esquerda em imagens de cineangiografia, para identificação de estenose. O algoritmo é baseado na comparação de esqueletos da árvore coronariana com um modelo topológico proposto pelos autores.

A identificação de estruturas tubulares é uma aplicação importante em estudos vasculares. Krissian *et al.* (2000) usaram uma abordagem multi-escala para extração de vasos de diferentes tamanhos. Frangi *et al.* (1999) também utilizaram análise em múltiplas escalas para quantificação do grau de estenose de vasos, para diagnóstico de doenças vasculares e planejamento de intervenções vasculares.

Todos os trabalhos citados objetivam a resolução de um problema específico na área médica e cada um deles apresenta contribuições importantes à área. Entretanto, todos apresentam limitações e a busca por métodos de identificação de estruturas em imagens médicas ainda é uma área de pesquisa desafiadora.

2.2.4. Utilização de abordagens em múltiplas escalas para identificação

A breve revisão apresentada na seção anterior mostra que algumas etapas fundamentais, e que não possuem soluções universais, são a detecção de características representativas e a criação de modelos e estruturas de dados para representação eficiente das estruturas presentes na imagem. O fato de objetos reais aparecerem de forma diferente, dependendo da escala de observação, tem implicações importantes para sua descrição. A noção de escala é muito importante quando se analisam dados em imagens por métodos

automáticos. A detecção de características em múltiplas escalas é uma tática para minimizar o problema da determinação do tamanho da máscara do operador, a ser adotado para a detecção das características da imagem utilizadas para representação. O tamanho da máscara depende do tamanho do órgão desejado, que apresenta grandes variações. Para a detecção ótima em uma única escala, o tamanho do órgão procurado deve ser conhecido *a priori*.

Alguns dos autores citados nesta revisão (Keserci *et al.*, 2002; Liu *et al.*, 2001; Krissian *et al.*, 2000; Frangi *et al.*, 1999) utilizaram técnicas de múltiplas escalas para a detecção das características utilizadas para classificação.

O objetivo deste trabalho é explorar a adoção de múltiplas escalas como ferramenta para a identificação de estruturas de interesse em imagens médicas. Para isso, avalia-se a utilização de detetores de características e uma representação de dados em múltiplas escalas. A teoria de múltiplas escalas utilizada neste trabalho é a **Teoria de Espaço de Escalas**. No capítulo 3, a seguir, será feita uma apresentação detalhada desta teoria e no capítulo 4, será apresentada a representação de dados multi-escala.

The scale, properly speaking, does not permit the measure of the intelligence, because intellectual qualities are not superposable, and therefore cannot be measured as linear surfaces are measured.

- Alfred Binet (sobre o teste de QI)

Capítulo 3

Espaço de escalas

Neste capítulo, é introduzido o conceito de representação de imagens utilizando espaço de escalas, no qual a imagem passa a ser constituída por um conjunto de versões suavizadas da imagem original. Essa representação tem sido utilizada nas áreas de Processamento de Imagem e Visão Computacional, pois o processo de suavização permite que, com a eliminação progressiva de detalhes da imagem, o sistema de processamento se concentre em um nível adequado de detalhe para a análise em questão. Duas características da representação em espaço de escalas a tornam bastante atraente para adoção em métodos para identificação de estruturas: a eliminação de detalhes da cena e a possibilidade de realização da busca em uma escala na qual o objeto de interesse se manifesta de forma mais clara ou intensa. Primeiramente, serão apresentados os conceitos básicos de representação em múltiplas escalas. A seguir, será feita uma apresentação detalhada da teoria de espaço de escalas linear e uma breve descrição dos espaços de escala não lineares. Será também discutida a questão da escolha da escala mais relevante para o processamento. Detalhes de implementação e alguns resultados serão vistos no final do capítulo.

3.1. Conceitos gerais sobre a abordagem utilizando múltiplas escalas

O conceito de utilização de múltiplas escalas para representação de imagens surgiu da observação de propriedades de visualização de objetos reais. Uma propriedade inerente a

esses objetos é que eles existem como entidades que fazem algum sentido apenas em algumas faixas de escala. O exemplo clássico utilizado para ilustrar essa propriedade é o conceito do galho de árvore, que faz sentido apenas em escalas de alguns centímetros a, no máximo, uns poucos metros. Não faz nenhum sentido discutir o conceito de galho no nível de nanômetro ou quilômetro. Nessas escalas, é mais relevante falar, respectivamente, a respeito das moléculas que formam a árvore e da floresta na qual a árvore cresce (Koenderink, 1984).

Imagens são conjuntos ordenados de dados que representam uma cena física, os quais são extraídos a partir da captura de informações presentes nessa cena. No processo de extração ou aquisição da imagem, é necessária a utilização de um instrumento de medida (como os olhos, uma câmara fotográfica ou um sistema de aquisição de imagens médicas). A imagem adquirida é capaz de exibir objetos em uma faixa de escalas, que é dependente da faixa percebida pelo instrumento. A faixa de escalas de um instrumento é limitada nos dois extremos: a escala interna é determinada pelas características de amostragem do sistema de medida (um cone ou um bastonete, a granulação da chapa de raios X); a escala externa é limitada pelo campo de visão do aparelho (Florack, 1994).

Para construir qualquer representação da imagem, é necessário extrair informações a partir da interação de seus dados com algum operador de imagem. Alguns problemas fundamentais em processamento de baixo nível e análise de imagens estão relacionados ao tipo de operador a ser utilizado, onde aplicá-lo e o tamanho da máscara de aplicação. Caso essas questões não sejam consideradas, a tarefa de interpretação dos resultados pode ser muito difícil (Lindeberg, 1994; Ter Haar Romeny, 1996).

Imagens são, também, observações do mundo real registradas através de medidas de alguma quantidade física. Conforme já mencionado acima, essa medida é caracterizada pela resolução, ou abertura, do instrumento de medida. Existe um compromisso entre o nível de detalhe e o campo de visão possíveis em uma medida. Se o que se deseja é visualizar pequenos detalhes, então a abertura deve ser pequena, o que significa que uma porção menor da cena poderá ser reproduzida. Por outro lado, uma abertura maior produz uma cena com menos detalhes, porém um campo de visão maior. Um bom exemplo desse

compromisso é a visualização da imagem de mamografia em duas resoluções diferentes, apresentadas na figura 1.2.

O conceito de faixa de medidas com resoluções diferentes, que corresponde a observações em uma faixa de escalas, é chamado de medidas de dados em múltiplas escalas. No caso de imagens digitais, o processo de medida em múltiplas escalas pode ser simulado pelo sistema de Visão Computacional, através da representação em múltiplas escalas (Lindeberg, 1994; Ter Haar Romeny, 1996). Essa representação embute os dados originais em um conjunto de imagens derivadas em função de um parâmetro de escala. Uma questão que surge imediatamente diz respeito a como construir essa representação: não é suficiente simplesmente reduzir a resolução espacial da imagem?

Um dos principais requisitos para a construção dessa representação é que as estruturas em escalas altas em representações de múltiplas escalas devem ser versões simplificadas de estruturas correspondentes em escalas mais baixas, ou seja, o método de suavização não deve criar estruturas novas. Esse requisito foi estabelecido de diversas formas por diferentes autores ((Koenderink, 1984; Yuille e Poggio, 1986; Lindeberg, 1994; Babaud *et al.*, 1986). Aliado aos requisitos de linearidade e invariância a deslocamento espacial, estes requisitos tornam a Gaussiana e suas derivadas a única solução possível para essa construção. Esse resultado deu origem à teoria de espaço de escalas linear, que será apresentada no item 3.2.

A idéia de representar dados em múltiplas escalas não é nova e já foi utilizada em outras abordagens como *quad-trees*, pirâmides e *wavelets* (Lindeberg, 1994).

Um dos principais argumentos apresentados em favor da teoria de espaço de escalas é a semelhança com os processos utilizados pela visão humana na tarefa de visualização e análise de imagens: existem vários dados de neurofisiologia e neuropsiquiatria indicando que o sistema de visão primária humano realiza tarefas em múltiplas escalas (Ter Haar Romeny, 1996; Koenderink, 1990). Os cones e bastonetes na retina formam campos receptores de formato circular em uma faixa enorme de escalas e são conectados a uma única célula ganglionar. Esta célula responde à intensidade luminosa ou a derivadas da intensidade luminosa até, cogita-se, quarta ordem, em uma escala correspondendo ao

tamanho do campo receptor (Llacer *et al.*, 1993). Os campos receptores na retina se projetam para o núcleo geniculado lateral (LGN) no tálamo. Daí as projeções vão para o córtex visual. Os perfis dos campos receptores no córtex possuem uma grande semelhança com as derivadas da gaussiana (Young^{3.1} 1987 *apud* Lei, 1999).

3.2. Espaço de escalas linear

3.2.1. Espaço de escalas

O conceito de espaço de escalas linear foi introduzido na literatura ocidental por Witkin (1983) e Koenderink (1984). Weickert (1997) mostrou que o conceito de espaço de escalas havia sido introduzido no Japão aproximadamente 20 anos antes de sua descrição do ocidente (Iijima^{3.2} 1962 *apud* Weickert, 1997). O desenvolvimento da teoria de espaço de escalas ocorreu como conseqüência das questões discutidas no item 3.1. A idéia básica dessa teoria é considerar uma imagem e todos os seus detalhes em diferentes níveis de escalas. Esse conceito foi resumido da seguinte forma por Koenderink (1984) em seu artigo original:

“Se o objetivo é extrair todas as estruturas presentes em uma imagem, esta deve ser analisada simultaneamente em todos os níveis de resolução e deve-se compreender as relações entre as imagens derivadas nos diferentes níveis de escala.”

O espaço de escalas é uma representação da imagem em diversas escalas, cada uma das quais refletindo a nova escala interna (ou resolução) da imagem, que incorpora a imagem original, $E(\vec{x})$, em um conjunto de imagens $\{H_s E(\vec{x}) \mid s \geq 0\}$. A cada nova escala, caracterizada pelo parâmetro de escala s , a imagem obtida pela aplicação do filtro H_s deve ser uma versão cada vez mais simplificada da original (Weickert, 1998; Florack *et al.*, 1994).

^{3.1} Young, R.A. **The gaussian derivative model for machine vision: visual cortex simulation** J. Optical Soc. Am. July, 1987.

^{3.2} Iijima, T. **Basic theory of pattern normalization (for the case of a typical one-dimensional pattern)**, Bulletin of the Electrotechnical Laboratory, v. 26, p. 368-288, 1962 (em japonês)

Na figura 3.1, são apresentados dois espaços de escalas, um para uma imagem 3D sintética com três cubos, e outro para uma imagem 2D cardíaca obtida por ressonância magnética.

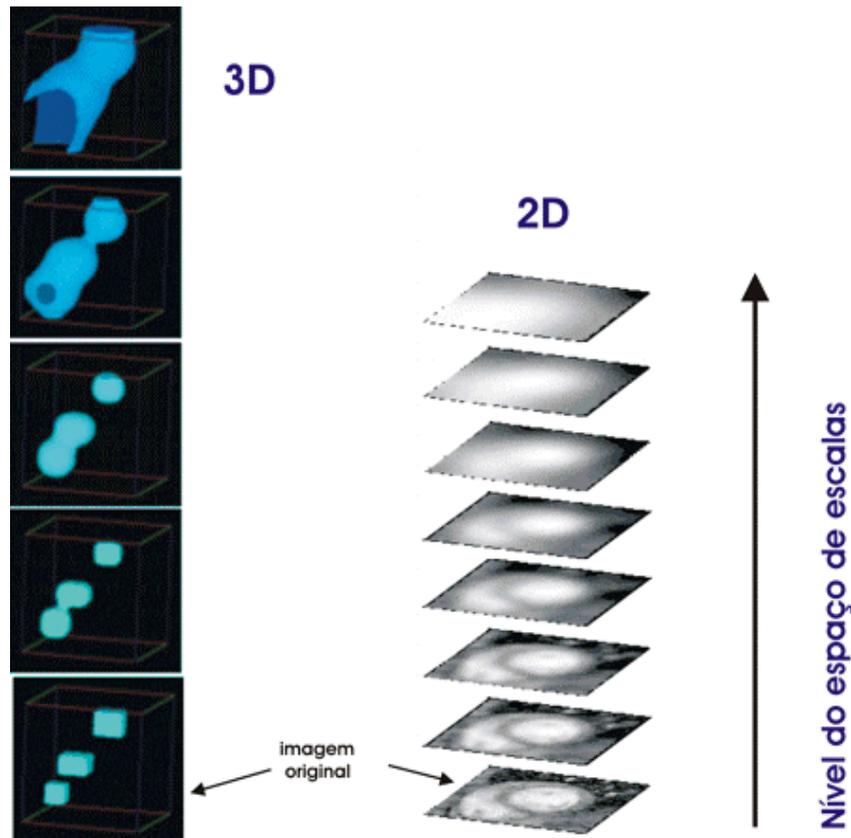


Figura 3.1. Esquema de espaço de escalas em 3D e 2D. À esquerda, é apresentado o espaço de escalas de uma imagem sintética (gerada por software desenvolvido neste trabalho), que contém três cubos. À direita, o espaço de escalas de uma imagem cardíaca obtida por ressonância magnética (imagem adquirida no Serviço de Ressonância Magnética da Divisão de Diagnóstico por Imagens – Instituto do Coração – HCFMUSP). Os espaços de escalas foram obtidos pela convolução da imagem original com a gaussiana (equação 3.5), com os valores de σ descritos pela equação 3.7.

Uma condição de arquitetura importante para a construção do espaço de escalas, definida por Ter Haar Romeny (1996), Koenderink (1984) e Florack *et al.* (1994), é a recursividade: para o nível inicial, $s=0$, a representação de espaço de escalas fornece a imagem original $E(\vec{x})$ e o processo de filtragem pode ser descrito por:

$$H_0 E(\vec{x}) = E(\vec{x}) \quad (3.1)$$

$$H_{s+v} E(\vec{x}) = H_s (H_v E(\vec{x})) \quad \forall v, s \geq 0 \quad (3.2)$$

Outras condições, de suavização e redução de informação, têm origem na necessidade da não criação de artefatos quando se passa de uma representação em escala mais fina para uma mais grosseira. O que se deseja é que, em escalas mais grosseiras, não existam estruturas adicionais causadas pelo processo de filtragem. Esta condição foi estabelecida de diferentes formas por diversos autores: não criar novas curvas de nível (Koenderink, 1984; Yuille e Poggio, 1986; Lindeberg, 1990), não realçar extremos locais (Babaud, 1986; Lindeberg, 1996b), diminuição do número de extremos locais (Lindeberg, 1990). Outra característica desejada é a invariância ao máximo de transformações possíveis na imagem, como rotação e translação.

Na formulação inicial da teoria de espaço de escalas, mais uma condição foi acrescentada, a de linearidade:

$$H_s (a E(\vec{x}) + b F(\vec{x})) = a H_s E(\vec{x}) + b H_s F(\vec{x}) \quad (3.3)$$

Foi demonstrado que a imposição da condição de linearidade restringe o gerador do espaço de escalas a uma única função, a função Gaussiana (Florack, 1994).

3.2.2. Teoria

O espaço de escalas linear consiste em representar a imagem em vários níveis de escala interna obtidos pela convolução da imagem original com filtros gaussianos com variâncias progressivamente maiores.

Para o desenvolvimento dessa teoria, supõe-se que o sistema de análise de imagens modelado seja equivalente ao sistema de visão primário, ou seja, completamente independente da geometria da imagem. A tarefa principal de tal sistema é estabelecer essa geometria em qualquer escala. A ausência de qualquer informação geométrica coloca algumas condições adicionais como linearidade, invariância com relação à translação e isotropia, apresentadas no item anterior. Essa abordagem fundamental foi adotada por

Witkin (1983), Koenderink (1984) e Yuille e Poggio (1986), que formularam uma condição *a priori* na forma de imposição de causalidade: nenhum ‘detalhe espúrio’ deve ser criado à medida em que a escala aumenta. Esta imposição, somada às condições de simetria, estabeleceu a função gaussiana como o construtor do espaço de escalas linear.

Para qualquer sinal N-dimensional $f : \mathbb{R}^N \rightarrow \mathbb{R}$, a sua representação no espaço de escalas $H : \mathbb{R}^N \rightarrow \mathbb{R}$ é definida pela convolução desse sinal com a função gaussiana (Ter Haar Romeny, 1996):

$$H(\vec{x}; s) = \int_{-\infty}^{+\infty} f(\vec{x} - \vec{\zeta}) g(\vec{\zeta}) d\vec{\zeta}, \quad \vec{\zeta} \in \mathbb{R}^N \quad (3.4)$$

$g : \mathbb{R}^N \rightarrow \mathbb{R}$ é a função gaussiana:

$$g(\vec{x}; \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{|\vec{x}|^2}{2\sigma^2}}, \quad \sigma \text{ possui dimensão de } \vec{x} \quad (3.5)$$

O parâmetro de escala s é uma característica da escala na qual a imagem está sendo observada e se relaciona com o parâmetro σ da função gaussiana por: $\sigma^2 = s$. $H(\vec{x}; s)$ é a intensidade do elemento \vec{x} na escala s .

A convolução da imagem com a gaussiana necessariamente aumenta a escala interna (ou seja, diminui a resolução). A pilha de imagens em função da escala interna é chamada de espaço de escalas (Florack, 1994). Como operador que atua em uma vizinhança, a gaussiana introduz um parâmetro, σ , que controla o tamanho dessa vizinhança. O tamanho da janela utilizada, por sua vez, controla o tamanho das estruturas que podem ser medidas em uma determinada escala. Diferentes tipos de medidas necessitam de janelas com tamanhos diferentes.

Koenderink (1984), em seu trabalho original, observou que a equação geradora do espaço de escalas linear é a solução da equação de difusão linear, com a imagem original, $E(\vec{x})$, como condição inicial:

$$\begin{cases} \frac{\partial H(\bar{x};s)}{\partial s} = \vec{\nabla} \cdot \vec{\nabla} H(\bar{x};s) = \Delta H(\bar{x};s) = \sum_{i=1}^D \frac{\partial^2 H(\bar{x};s)}{\partial x_i^2} \\ H(\bar{x};0) = E(\bar{x}) \end{cases} \quad (3.6)$$

D é a dimensão da imagem, $\vec{\nabla} H$ é o gradiente de H e $\vec{\nabla} \cdot \vec{\nabla} H$ é o divergente do gradiente.

$H(\bar{x};s)$ pode ser interpretada como uma função de densidade que descreve a quantidade de uma substância em cada ponto da imagem. Essa substância é a informação física representada por $H(\bar{x};s)$. À medida que o parâmetro de escala aumenta, essa substância se difunde, das regiões de maior concentração para as regiões de menor concentração, num processo de homogeneização da substância em todo o domínio da imagem. É um processo análogo à difusão de calor em uma placa de metal que, com a passagem do tempo, torna a temperatura na placa cada vez mais uniforme, até que se torne constante (Ter Haar Romeny, 1996).

A solução completa $H(\bar{x};s)$, com condição inicial $H(\bar{x};0) = E(\bar{x})$, é o espaço de escalas e cada amostra em uma escala diferente é uma versão da imagem original após o processo de suavização. Seguindo esse raciocínio, pode-se visualizar o processo de suavização com a gaussiana como um processo contínuo que evolui a partir da imagem original.

Koenderink (1984) mostrou que, para manter a propriedade de invariância de escala, a amostragem do parâmetro de escalas, σ , deve ser logarítmica. Para implementação do banco de filtros gaussianos, normalmente é introduzido um novo parâmetro, τ , que varia linearmente ao longo das escalas e se relaciona com o parâmetro σ por:

$$\sigma_n = \varepsilon e^{n \cdot \tau}, \quad n \in N \quad (3.7)$$

ε é a resolução espacial da imagem original. Para $\varepsilon = 1$, o nível zero do espaço de escalas corresponde à imagem original (Vincken, 1995). Esse valor de ε será utilizado ao longo deste texto. A cada valor de n está relacionado um nível no espaço de escalas. Remetendo à figura 3.1, n representa o nível da escala, s e σ são parâmetros relacionados à resolução, ou escala interna, de cada nível e τ está relacionado ao espaçamento entre os níveis.

Na figura 3.2 são apresentados 16 níveis do espaço de escalas linear construído para uma imagem de corte de tórax de ressonância magnética.

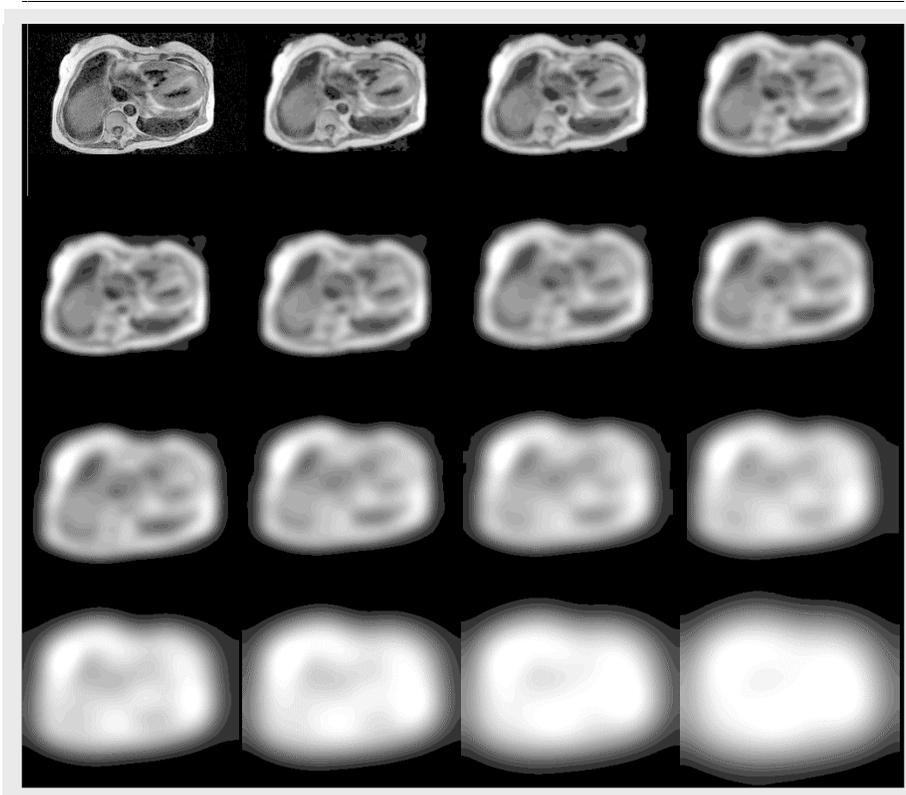


Figura 3.2. Dezesesseis níveis do espaço de escalas linear de um corte de tórax por ressonância magnética com $\tau = 0,19$. A imagem no canto superior esquerdo é a imagem original. (Imagem adquirida no Serviço de Ressonância Magnética da Divisão de Diagnóstico por Imagens – Instituto do Coração – HCFMUSP).

3.2.3. Derivadas numéricas utilizando espaço de escalas

Um resultado muito útil da teoria de espaço de escalas linear é o fato de as derivadas da função Gaussiana também serem soluções da equação de difusão e, juntamente com a Gaussiana, formarem um conjunto completo de operadores diferenciais (Nielsen *et al.*, 1994). O resultado de ordem zero é um escalar (é a própria intensidade da imagem), enquanto que todos os outros resultados de ordem superior são quantidades tensoriais como, por exemplo, o resultado de primeira ordem, o gradiente, é um vetor. Essa propriedade tem sido utilizada para obtenção de derivadas numéricas em imagens (Pizer, 1994; Niessen, 1995; Niessen, 1997; Fridman, 2004; Gutierrez, 2005).

A obtenção de derivadas numéricas é um problema mal posto (Bertero *et al.*, 1988; Florack *et al.*, 1994). De acordo com Hadamard (Hadamard^{3.3} 1902 *apud* Bertero, 1988) um problema é bem posto se: sua solução (1) existe, (2) é única e (3) depende continuamente dos dados iniciais. Em função do ruído, inerente às imagens digitais, a função de intensidade, $E(\vec{x})$, pode ser descontínua por toda a imagem. Desta forma, uma pequena variação nos dados originais pode causar uma variação substancial na operação de diferenciação, violando a terceira condição. Alguns algoritmos para diferenciação de imagens tentam superar este problema regularizando os dados, por exemplo, suavizando a matriz de intensidade original. Entretanto, os dados não devem ser modificados, e o que se deve buscar é a regularização do operador. Uma imagem do espaço de escalas $H(\vec{x}; \sigma)$ é uma função suave para todos os valores de $\sigma > 0$, tornando a diferenciação nas escalas um processo bem posto (Florack *et al.*, 1994).

Um resultado importante da teoria de espaço de escalas pode ser obtido tomando a identidade dada pela expressão (3.8):

$$\partial\{E(\vec{x}) \otimes g(\vec{x}; \sigma)\} = \partial E(\vec{x}) \otimes g(\vec{x}; \sigma) = E(\vec{x}) \otimes \partial g(\vec{x}; \sigma) \quad (3.8)$$

\otimes representa a operação de convolução.

Para obter de forma bem posta derivadas parciais cartesianas de ordem n de uma imagem na escala σ , $H(\vec{x}; \sigma)$, é necessário apenas convoluir a imagem original $E(\vec{x})$ com as derivadas parciais correspondentes da gaussiana $g(\vec{x}; \sigma)$. Este resultado foi utilizado em alguns trabalhos do nosso grupo^{3.4}, nos quais as derivadas regularizadas são utilizadas para determinação do fluxo óptico em imagens cardíacas por medicina nuclear (Gutierrez *et al.*, 1997b, 2005) e por ressonância magnética (Gutierrez *et al.*, 1997a, 1998a, 1998b, 2004), com o objetivo de analisar o movimento das paredes do ventrículo esquerdo. Na figura 3.3.a, apresenta-se um conjunto de doze imagens cardíacas obtidas ao longo do ciclo cardíaco e sincronizadas com o eletrocardiograma. Em 3.3.b, são apresentadas as derivadas parciais, nas três direções e no tempo, obtidas utilizando a equação 3.8.

^{3.3} J. Hadamard, "Sur les problèmes aux dérivées partielles et leur signification physique," Princeton University Bulletin, vol. 13, 1902.

^{3.4} Serviço de Informática - Instituto do Coração - HCFMUSP

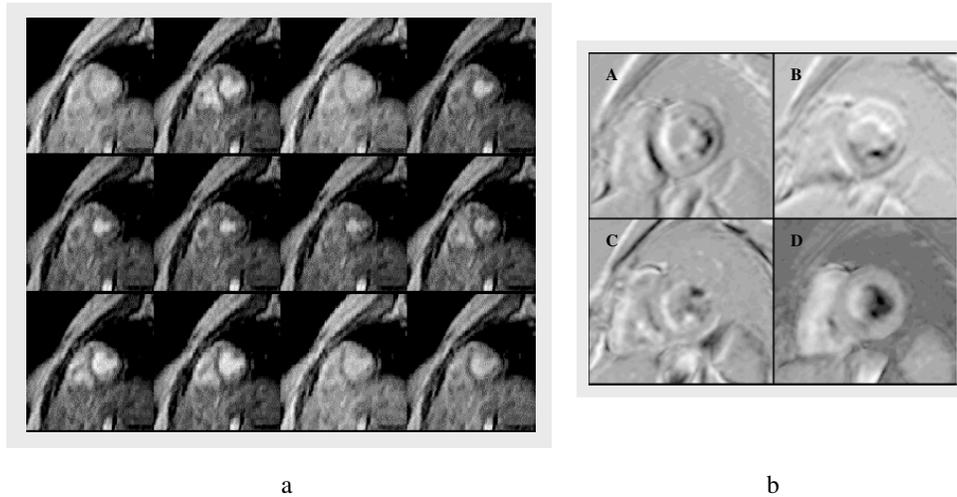


Figura 3.3. (a) Doze cortes de um volume cardíaco por ressonância magnética – dimensões $256 \times 256 \times 10 \times 12$ – ao longo do ciclo cardíaco. (b) derivadas parciais obtidas pela abordagem de espaço de escalas utilizando $\sigma = 1,42$: A, B, C, e D são, respectivamente, as derivadas nas direções y , x , z e no tempo. Para o cálculo das derivadas, realizou-se uma interpolação linear nas direções z e t no conjunto de imagens da figura a. (Imagens adquiridas no Serviço de Ressonância Magnética – Divisão de Diagnóstico por Imagem - Instituto do Coração – HCFMUSP).

Esse resultado permite a extração de derivadas de qualquer ordem para dados discretos. Existe, entretanto, uma relação estreita entre a ordem de diferenciação, a escala do operador e a acurácia do resultado. Isto levanta, pela primeira vez, a questão fundamental de qual deve ser a melhor escala para um problema específico. Este ponto será retomado mais adiante neste texto.

3.2.4. Operadores diferenciais utilizando espaço de escalas

A metodologia de análise de imagens no espaço de escalas foi estendida para incluir as derivadas parciais da equação 3.5 de diferentes ordens, como filtros úteis para a tarefa de análise de imagens.

Um operador de escala diferencial em três dimensões foi descrito por Llacer (1993):

$$G_{m,n,p}(x, y, z, s) = \frac{\partial^{p+n+m} G_{m,n,p}(x, y, z, s)}{\partial x^n \partial y^m \partial z^p} \quad (3.9)$$

x, y, z são as dimensões espaciais da imagem, s é a dimensão de escala e p, n e m indicam a ordem da derivada.

Por exemplo, o operador módulo diferencial gradiente pode ser descrito pela expressão 3.10.

$$|\text{Grad}(\bar{x}; s)|^2 = \left(\frac{\partial G(\bar{x}; s)}{\partial x} \right)^2 + \left(\frac{\partial G(\bar{x}; s)}{\partial y} \right)^2 + \left(\frac{\partial G(\bar{x}; s)}{\partial z} \right)^2 \quad (3.10)$$

Na figura 3.4, apresenta-se a aplicação do operador módulo diferencial gradiente, dado pela expressão 3.10, a um corte da seqüência apresentada na figura 3.3.a.

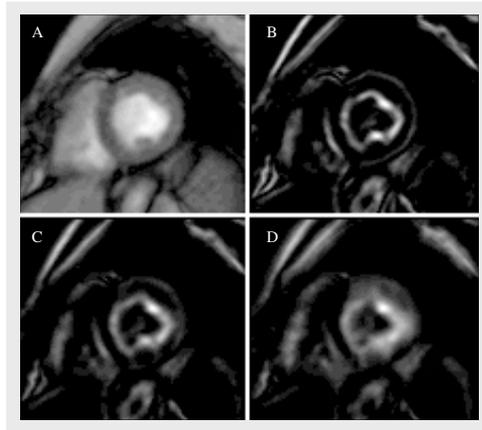


Figura 3.4. a) um corte 2D de um volume 3D cardíaco de ressonância magnética. Resolução espacial de 60x60x10, resolução temporal de 12 imagens por ciclo cardíaco. b), c) e d) módulo do gradiente para $\sigma = 1,42$, $\sigma = 2,72$ e $\sigma = 4,48$, respectivamente. (Imagem adquirida no Serviço de Ressonância Magnética – Divisão de Diagnóstico por Imagem - Instituto do Coração – HCFMUSP).

3.2.5. Invariantes geométricos nas escalas como descritores da geometria da imagem

Uma vez que o conjunto de derivadas parciais para todos os elementos da imagem até ordem N , ao longo das escalas, tenha sido calculado, estão disponíveis todas as derivadas da imagem até ordem N . Entretanto, cada derivada individual, por exemplo, $\partial L(\bar{x}; s)/\partial x$, não representa nenhuma propriedade com algum significado geométrico, pois

a escolha dos eixos é completamente arbitrária (Ter Haar Romeny, 1996). Existe a possibilidade de rotação do sistema de coordenadas, o que causaria um resultado diferente para a derivada e que não tem, obviamente, nenhuma relação com a imagem.

Qualquer propriedade que seja invariante a transformações no sistema de coordenadas deve estar ligada à própria imagem e, portanto possui alguma interpretação geométrica (Koenderink, 1992). O oposto também é verdadeiro: qualquer propriedade da imagem pode ser expressa através de uma função invariante (ou simplesmente ‘invariante’). Existe, assim, uma relação íntima entre teoria de invariantes e a geometria diferencial (Florack, 1992).

Embora seja possível fazer uma descrição da geometria da imagem independente do sistema de coordenadas, na fase de implementação é necessário utilizar coordenadas específicas. Qualquer sistema de coordenadas pode ser escolhido, desde que se assegure que as funções de interesse sejam independentes dessa escolha particular. O termo ‘invariante’ sempre implica a existência de um grupo de transformações permitidas (Florack *et al.*, 1994).

No presente trabalho, serão utilizadas funções invariantes em relação a grupos básicos de transformações muito úteis quando se analisam imagens médicas: o grupo de rotações, o grupo de translações e o grupo de reflexões. As combinações especiais de derivadas da imagem que exibem tal conjunto de invariâncias sob transformações de coordenadas cartesianas são chamadas invariantes cartesianas diferenciais. Pode-se construir um número infinito de invariantes em cada ponto da imagem, mas pode-se mostrar (Florack, 1992) que existe apenas um pequeno número de invariantes independentes entre si. Isso quer dizer que, para uma dada ordem N de diferenciação, pode-se definir qualquer quantidade geometricamente significativa em função dessas invariantes independentes. Esse resultado será utilizado no capítulo 4.

3.2.6. Limitações do espaço de escalas linear

A abordagem de espaço de escalas linear apresenta um grande problema para sua utilização em análise automática de imagens, que é o fato de que não apenas o ruído é

suavizado, mas também elementos importantes da imagem, como bordas (Weickert, 1998). Esse efeito pode ser visualizado na figura 3.2, na qual as estruturas presentes na imagem são rapidamente suavizadas e em poucos níveis já é difícil a visualização de suas bordas.

A redução indiscriminada de informação de baixa escala (como ruídos, bordas e pequenas estruturas), associada com suavização uniforme, pode remover informações importantes sobre estruturas reais que tenham componentes de alta e baixa escala (interior de objetos e suas bordas). Como as componentes de baixa escala são normalmente utilizadas na etapa de segmentação, a utilização desse construtor (a gaussiana) introduz incertezas na localização precisa das bordas. Na figura 3.4 pode-se verificar que para os valores maiores de σ , a imagem de gradiente apresenta valores altos (que correspondem às bordas das estruturas) em uma faixa cada vez mais larga e indistinta, o que introduz ambigüidade ou incerteza na localização precisa das bordas em questão.

Idealmente, o que se deseja é tornar mais eficazes as medidas em pontos de descontinuidade na imagem suavizando as regiões de fundo, porém mantendo as bordas perceptíveis. Essa necessidade motivou a formulação da teorias de espaço de escalas não lineares.

3.3. O embasamento físico para o processo de difusão

Existe a noção intuitiva de difusão como um processo físico que tende a equilibrar diferenças de concentração sem criar ou destruir massa. Essa propriedade de equilíbrio é expressa pela lei de Fick (Weickert, 1998):

$$\vec{j} = -D \cdot \vec{\nabla}L \quad (3.11)$$

A equação acima afirma que um gradiente de concentração $\vec{\nabla}L$ causa um fluxo \vec{j} que tende a compensar o gradiente. A relação entre $\vec{\nabla}L$ e \vec{j} é descrita pelo tensor de difusão D , que é uma matriz simétrica positiva. No caso em que $\vec{\nabla}L$ e \vec{j} são paralelos, o processo de difusão é dito isotrópico. O tensor pode, então, ser substituído pelo escalar, chamado de constante de difusão, d . No caso geral anisotrópico, \vec{j} e $\vec{\nabla}L$ não são paralelos.

A observação de que a difusão apenas transporta massa, sem criá-la ou destruí-la, é expressa pela equação da continuidade:

$$\frac{\partial L}{\partial t} = -\vec{\nabla} \cdot \vec{j}, \quad t \text{ é o tempo.} \quad (3.12)$$

Colocando a equação de Fick (3.11) na equação de continuidade (3.12), chega-se à equação de difusão:

$$\frac{\partial L}{\partial t} = \vec{\nabla} \cdot (D \cdot \vec{\nabla} L) \quad (3.13)$$

Essa equação surge em muitos fenômenos de transporte na física. No contexto de transferência de calor, ela é chamada de equação de difusão de calor.

Conforme já colocado no item 3.2.2, em processamento de imagens pode-se identificar a concentração na equação 3.13 com o valor de intensidade de um elemento em uma dada posição. Se o tensor de difusão for constante por todo o domínio da imagem, trata-se de um processo de difusão homogênea. Uma filtragem dependente da posição espacial é chamada difusão não homogênea. Frequentemente, o tensor de difusão é uma função da estrutura diferencial da própria imagem, gerando os espaços de escala não lineares (Weickert, 1998).

3.4. Espaços de escala não lineares

A equação de difusão linear 3.6 é um caso particular da equação geral de difusão 3.13, na qual o tensor de difusão é constante por toda a imagem. Em espaços de escala não lineares, essa condição não é válida (Weickert, 1998; Florack 1995).

Nos espaços de escala não lineares são utilizados métodos de suavização adaptativos, que são baseados na idéia de se aplicar um processo que depende de propriedades locais da imagem, eliminando a restrição de isotropia na resolução da equação de difusão. Um enorme esforço tem sido feito no sentido de se encontrar construtores de espaço de escalas que, simultaneamente, suavizem as regiões homogêneas da imagem mantendo estruturas de interesse (Alvarez *et al.*, 1992; Kimia *et al.*, 1994; van den

Boomgaard e Smeulders, 1994; Jackway e Deriche, 1996; Kimmel, 1997; Weickert, 1998; Perona e Malik, 1990).

Essas pesquisas também são feitas em concordância com os resultados das pesquisas de visão biológica. O primeiro estágio de visualização é feito sem qualquer comprometimento e com total ausência de informações *a priori*. Conforme descrito no item 3.1, as informações formadas nos campos receptivos da retina são projetadas para o núcleo geniculado lateral (LGN) e daí para o córtex visual, no modelo que é contemplado pelo espaço de escalas linear. Existe, entretanto, uma projeção maciça de fibras retroalimentadoras do córtex visual para o LGN: aproximadamente 50% das sinapses do LGN são derivadas dos neurônios corticogeniculados, enquanto apenas 10-20% são da retina. Essa enorme retroalimentação fornece a idéia de que o sistema de visualização primário pode modificar os campos receptivos em função da própria imagem. Medidas recentes dos campos receptivos mostraram que muitos deles apresentam perfis de sensibilidade extremamente variáveis no tempo. Mais ainda, o sistema visual pode ser considerado como um sistema em cascata, no qual os níveis mais altos de informação com relação à tarefa, modelo ou memória podem ser utilizados para ajustar os processos iniciais (Ter Haar Romeny, 1996).

De maneira análoga, a teoria de espaço de escalas não lineares explora a possibilidade de utilização das informações geométricas obtidas na fase de processamento primário, como parâmetros dos filtros construtores de espaços de escalas e direcionamento do processo de difusão para uma determinada tarefa. Existem diversas abordagens para o problema, com uma enorme quantidade de equações para geração do espaço de escalas, entre as quais pode-se citar: (i) equações de difusão com coeficientes de condução variáveis, (ii) curvas ou superfícies de evolução dirigidas pela geometria, (iii) abordagem morfológica. A seguir, será feita uma descrição sucinta de cada uma delas.

3.4.1. Difusão com condutância variável

Sabe-se que o espaço de escalas linear tem uma desvantagem principal que é o borramento de bordas. Uma alternativa natural para diminuir os problemas de suavização de

bordas é a introdução de retroalimentação no processo de difusão, através da adaptação da constante de difusão d ao gradiente da imagem.

O primeiro filtro para difusão não linear foi proposto por Perona e Malik (1990). Esse trabalho inicial deu um grande impulso à pesquisa de espaços de escala não lineares. A proposta foi tornar a difusão decrescente em função do gradiente. O processo de difusão passa a ser, então, dependente de características locais da imagem: os locais de alto gradiente funcionam como uma região de isolamento, não permitindo a difusão dos valores de intensidade através deles. Em regiões homogêneas, o resultado de sua aplicação é muito semelhante ao da gaussiana.

Entretanto, o ruído presente nas imagens produz gradientes altos em todas as direções. Para as escalas mais baixas, regiões com alto valor de gradiente, porém sem significado na imagem (normalmente produto de ruído) são mantidas (Niessen, 1995). A difusão também tende a produzir várias superfícies descontínuas.

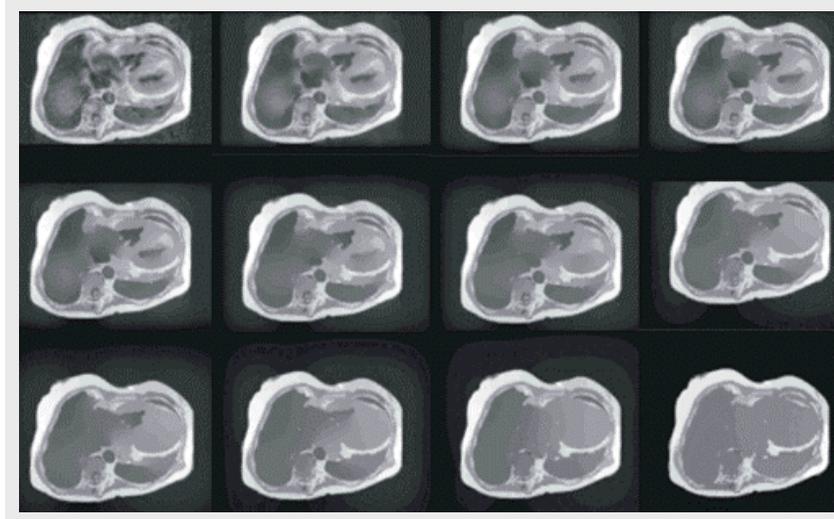


Figura 3.5. Doze escalas do espaço de escalas não linear utilizando difusão com condutância variável, construídas a partir da proposta de Black e Sapiro. A imagem no canto superior esquerdo é a imagem original. (Imagem adquirida no Serviço de Ressonância Magnética – Divisão de Diagnóstico por Imagem - Instituto do Coração – HCFMUSP).

Muitas variações da definição original foram propostas (Catté *et al.*, 1992; Gerig *et al.*, 1992; You *et al.*, 1996; Nitzberg e Shiota, 1992). Em particular, Black e Sapiro (1998)

utilizaram uma função para determinação de bordas na equação de difusão anisotrópica baseada no estimador de Tukey, que preserva bordas mais nitidamente do que na proposta original de Perona e Malik. Na figura 3.5, apresenta-se o espaço de escalas não linear, construído a partir da proposta de Black e Sapiro, para uma imagem de tórax por ressonância magnética.

3.4.2. Outras abordagens

Existem inúmeras abordagens para a construção de espaços de escalas não lineares. Aqui apresentaremos, a título de exemplo, duas dessas teorias.

Fluxos geométricos ou evolução de curvas

Esta abordagem considera a evolução de curvas e superfícies como função da geometria da imagem. No processo de difusão utilizando geometria, a difusão é máxima na direção tangencial às curvas e nula na direção normal. Kimia *et al.* (1994) pesquisou esta abordagem para a decomposição de formas e sua descrição em múltiplas escalas.

Espaços de escalas morfológicos

Em morfologia matemática, um espaço de escalas é criado pela erosão ou dilatação da imagem utilizando um elemento estruturante com tamanho crescente. Pode-se unir a dilatação e erosão na escala zero para formar uma operação de multiescala única, que unifica as duas operações morfológicas. Para escalas positivas, efetua-se uma dilatação e para escalas negativas, uma erosão (Jackway e Deriche, 1996).

3.5. Seleção de escalas

3.5.1. Conceito de escalas apropriadas

O conceito básico presente na análise de imagens com espaço de escalas é que o grau de suavização no qual um objeto desaparece revela o tamanho desse objeto. É por esse motivo que o parâmetro de suavização é chamado de escala (Majer, 2000). De acordo com a teoria de espaço de escalas, qualquer objeto em uma imagem tem uma posição e uma escala. Para encontrar tanto a posição quanto a escala adequada de um objeto, a imagem deve ser

suavizada e analisada em todos os possíveis graus, no caso de desconhecimento do conteúdo da imagem (Koenderink, 1984).

A representação de espaço de escalas é adequada para a tarefa de detecção de informações relevantes na imagem (Majer, 2000). Para realizar essa tarefa de forma eficiente, é necessário descrever cada objeto na chamada escala apropriada.

Para encontrar as escalas apropriadas, é necessário analisar a imagem em todas as escalas do espaço de escalas e escolher aquelas que possam ser descritas como **particularmente informativas** (Majer, 2000). As escalas particularmente informativas, ou apropriadas, são aquelas nas quais o objeto de interesse pode ser detectado. A importância da escolha das escalas apropriadas pode ser demonstrada pela análise dos dois exemplos apresentados no capítulo 1. No exemplo da imagem de mamografia (figura 1.2), uma aplicação para identificação das regiões de microcalcificações deveria trabalhar em níveis baixos do espaço de escalas; caso se desejasse primeiramente identificar a mama, para depois visualizar as microcalcificações, os níveis mais apropriados seriam níveis mais altos do espaço de escalas. Para a imagem de Medicina Nuclear (figura 1.3), também apresentada no capítulo 1, em uma aplicação cujo objetivo fosse identificar as regiões sugestivas de metástase, os níveis mais apropriados seriam intermediários no espaço de escalas, pois em níveis muito baixos o ruído tende a mascarar as regiões de metástase com baixo contraste e nos muito altos, a suavização torna a identificação muito imprecisa.

Outra motivação, de ordem mais técnica de processamento de imagens, para a seleção de escalas, diz respeito aos operadores utilizados para detecção de características. Para conseguir qualquer representação a partir dos dados de imagens é necessário que se extraiam informações utilizando operadores que interajam com eles. Algumas questões se colocam em relação a esse ponto. Que operadores usar? Onde aplicá-los? Quais parâmetros e valores eles devem ter? Nos operadores diferenciais utilizando espaço de escalas definidos no item 3.2.4, a dependência do tamanho do operador é explícita na expressão 3.9, na qual as derivadas são aplicadas à gaussiana em função da escala σ . Como os operadores são parametrizados em função da posição e da escala, é natural procurar não apenas as posições que contêm mais informações, mas também as escalas.

O ajuste automático da faixa de escalas é um problema agudo em processamento automático de imagens. A extraordinária capacidade do sistema visual humano para se ajustar automaticamente à faixa de escalas adequada para realizar determinada tarefa, constitui uma das características importantes de sua enorme habilidade para análise qualitativa de imagens.

3.5.2. Métodos para seleção de escalas

A determinação do parâmetro de escala mais adequado não é um problema trivial e a pesquisa por métodos automáticos para seleção de escala tem despertado interesse em muitas áreas (Pauly *et al.*, 2003). Lindeberg (1998) foi um dos primeiros autores a apresentar uma proposta para seleção de escalas. Majer (2000) propôs um método, que em linhas gerais é muito semelhante ao de Lindeberg.

Os trabalhos de Lindeberg e Majer tentaram estimar as posições e escalas mais apropriadas para a análise de imagens sem conhecimento *a priori*. As propostas, basicamente, consistiam dos seguintes passos:

- suavizar a imagem em graus variados;
- aplicar operadores e determinar extremos locais (máximos e mínimos);
- determinar as posições e escalas particularmente informativas, em função desses extremos locais.

O princípio proposto para a seleção de escalas afirmava que a escala na qual um determinado operador normalizado assumir máximo local deve refletir o tamanho característico de uma estrutura correspondente. Assim, o conjunto de máximos locais reflete os tamanhos das estruturas presentes na imagem. Pauly *et al.* (2003) utilizaram o mesmo princípio para selecionar as escalas.

Elder e Zucker (1998) descreveram a utilização de *escala mínima confiável* para estimativa local de bordas. Para os autores, escala confiável significa que, a partir dessa escala e em escalas mais altas, a probabilidade de erro na estimativa das bordas é inferior a um certo nível de tolerância.

3.6. Implementação

3.6.1. Criação das imagens de espaço de escalas

A implementação do espaço de escalas linear foi efetuada no domínio espacial, no qual o espaço de escalas linear é construído através de um processo de suavização por meio da convolução da imagem original com o filtro gaussiano, com valores crescentes de σ . Discute-se, na literatura, a respeito do filtro a ser utilizado no caso discreto, pois a gaussiana é a solução da equação de difusão para o caso contínuo. Lindeberg (1990) apresentou uma solução para a implementação discreta da teoria, que se aproxima da gaussiana conforme a escala aumenta. Existem ainda propostas de filtros recursivos (incluindo a gaussiana e suas derivadas) iniciada por Deriche (1993). Uma análise realizada por Fidrich (1994) mostrou que, no primeiro caso existe a desvantagem de que os filtros não podem ser implementados de forma isotrópica e separável e, no segundo, as combinações não lineares de derivadas presentes na metodologia podem causar um acúmulo de erros de computação, que possivelmente produzirão resultados imprecisos para os descritores diferenciais. A construção do espaço de escalas linear através da convolução com a gaussiana discreta (com o tamanho do filtro definido a partir da porcentagem de energia perdida pelo processo de truncagem) foi considerada satisfatória por esse estudo, e é bastante utilizada em trabalhos que utilizam o espaço de escalas linear. Na implementação deste trabalho, essa proposta foi utilizada para geração do espaço de escalas linear. Como alternativa a esta implementação, a suavização da imagem pode ser realizada no domínio de Fourier. Sua principal vantagem é o menor tempo de processamento em escalas mais altas, especialmente para imagens de modalidades com resolução espacial maior (Vincken, 1995). Os experimentos realizados neste trabalho foram realizados com imagens de resolução baixa e média e os tempos de processamento obtidos foram considerados satisfatórios.

Neste trabalho, o espaço de escalas linear é criado pela convolução da imagem original com filtros gaussianos discretos, com máscaras de largura crescente. O tamanho da máscara de convolução $(2a + 1)$, para cada parâmetro de escala σ , é definido em função da

porcentagem (δ) da energia da função gaussiana perdida como consequência da truncagem (Fidrich, 1994):

$$a = \sqrt{-\pi / (2 \ln \delta)} \cdot \sigma \quad (3.14)$$

Na implementação da convolução, foram utilizadas as propriedades de separabilidade e simetria da gaussiana.

Uma vez construído o espaço de escalas, cada amostra do conjunto é chamada de nível. Os níveis são numerados, começando em um, na imagem com menor valor de σ . É interessante observar que a análise se inicia em uma imagem na qual já tenha ocorrido suavização. Segundo Fiedrich (1994) a imagem original só poderia ser utilizada como o primeiro nível do espaço de escalas se a sua qualidade fosse excelente. Em imagens médicas, essa não é a regra, pois elas são freqüentemente corrompidas pelo ruído de aquisição. O procedimento mais correto em uma análise de espaço de escalas é considerar a primeira imagem suavizada como o primeiro nível.

3.6.2. Obtenção dos diferenciais nas escalas

No caso contínuo, existem, em princípio, duas formas equivalentes de calcular os diferenciais nas escalas: diferenciando o sinal suavizado ou convoluindo o sinal com um filtro de diferenciação suavizado.

No caso discreto, entretanto, essa relação não é válida (Fidrich, 1994; Lindeberg, 1990): um operador diferencial com máscara de tamanho pequeno aplicado a uma imagem suavizada com um operador com máscara de tamanho grande vai evidenciar as variações locais da estrutura, mas não as globais. Nos experimentos deste trabalho, foi utilizada a convolução do sinal com a máscara de diferenciação.

3.6.3. Linguagem de programação e ferramentas de desenvolvimento

As rotinas para criação do espaço de escalas linear, incluindo as rotinas para cálculo de derivadas utilizando o conceito de espaço de escalas, foram implementadas em ANSI C. Foi criada uma biblioteca *libscale.so*, que contém as rotinas para leitura e escrita de arquivos, geração das máscaras do filtro gaussiana e suas derivadas. Para a criação do

espaço de escalas, foi implementado o programa *gauss*, que utiliza a rotina *GaussConvolve* da biblioteca *libscale*. O programa permite o processamento de dados 1D (sinais), 2D (imagens bi-dimensionais), 3D (imagens tri-dimensionais) e 4D (séries temporais de imagens tri-dimensionais). O número de escalas e o valor de τ são parâmetros determinados em tempo de execução. Rotinas para criação de imagens de combinações de derivadas da imagem são criadas a partir da utilização da rotina *DerivConvolve* da biblioteca *libscale*.

Para visualização das imagens, foi utilizado o AVS® – *Advanced Visual System*, que é um ambiente para visualização e processamento de dados. O ambiente possui ferramentas de visualização e processamento para dados 1D, 2D e 3D. A interface para criação das redes de visualização e processamento é bastante amigável e permite, também, o desenvolvimento de novos módulos de processamento. Neste trabalho, o ambiente AVS foi utilizado apenas para visualização de imagens, pois embora C seja uma das linguagens de desenvolvimento para criação de novos módulos no AVS, o código final apresenta algumas diferenças em relação ao ANSI C, especialmente nas rotinas de manipulação de memória. Desde o princípio do desenvolvimento dos módulos deste trabalho, um dos requisitos estabelecidos foi a portabilidade. Assim, optou-se por não utilizar a ferramenta de desenvolvimento de novos módulos do AVS. Os resultados apresentados no item a seguir foram obtidos em um servidor Sun Ultra Enterprise 450, Ultra4, 2 GB de RAM (CFP 2000 = 11,1)^{3.5}.

3.7. Resultados

Ao longo deste capítulo, foram apresentadas algumas imagens obtidas através da utilização das rotinas desenvolvidas nesta etapa. A figura 3.1, que ilustra o conceito de espaço de escala em imagens bidimensionais e tridimensionais, foi obtida pela aplicação do programa *gauss* a dois conjuntos de imagens, um sintético (3D) e um corte cardíaco (2D) de um volume por ressonância magnética. A figura 3.2 apresenta o espaço de escalas de um corte de tórax por ressonância magnética, também obtido pela aplicação da rotina *gauss*.

^{3.5} Valor obtido em www.spec.org

Na figura 3.3, é ilustrada a determinação de derivadas utilizando o conceito de espaço de escalas. A figura mostra o resultado obtido pela aplicação da rotina *genDerivatives* a uma seqüência temporal de um corte 2D de um volume cardíaco por ressonância magnética, obtido em diversos pontos do ciclo cardíaco. São apresentadas as derivadas obtidas nas três dimensões espaciais e no tempo. A figura 3.4 ilustra a aplicação de um operador diferencial (no caso da figura, o operador gradiente) a um corte pertencente ao volume de imagens apresentado na figura 3.3. As imagens de gradiente foram obtidas utilizando o programa *gradient* com três valores de σ , para ilustrar a influência do parâmetro no resultado da operação.

A figura 3.5 apresenta um espaço de escalas não linear construído para um corte de tórax por ressonância magnética, utilizando o programa *tuckey*, cuja implementação foi baseada no trabalho de Black e Sapiro (1998).

Como resultado final deste capítulo são apresentados dados sobre o desempenho das rotinas implementadas. Na figura 3.7 mostram-se os tempos de processamento para obtenção das imagens do espaço de escalas de uma imagem 2D sintética, apresentada na figura 3.6, em três resoluções distintas: 64 x 64, 128 x 128 e 256 x 256 pixels. Utilizou-se o valor de $\tau = 0,19^{3.6}$.

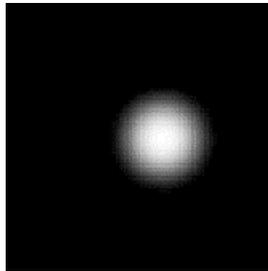


Figura 3.6. Imagem sintética simples (criada por software desenvolvido neste trabalho) utilizada para verificação do desempenho das rotinas de geração do espaço de escalas em 3 resoluções diferentes.

^{3.6} O valor de τ foi determinado empiricamente. No apêndice IV apresenta-se uma análise qualitativa da influência desse parâmetro.

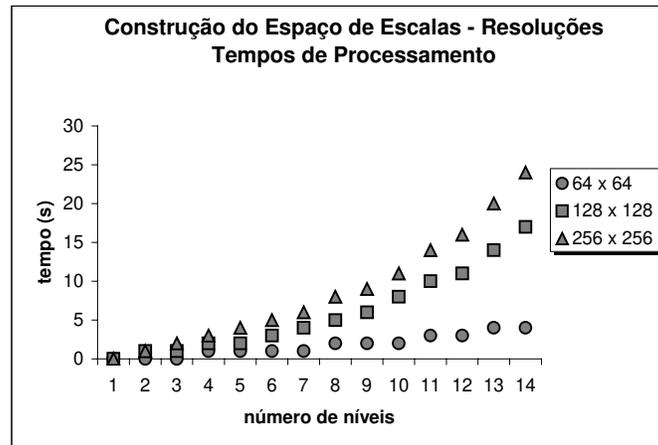


Figura 3.7. Tempos de processamento para criação do espaço de escalas com diferentes níveis, para a imagem apresentada na figura 3.7, em três resoluções: 64 x 64, 128 x 128 e 256 x 256 pixels. $\tau = 0,19$. A tabela com os valores dos tempos é apresentada no Apêndice I. Os valores foram obtidos em um servidor Sun Ultra Enterprise 450.

Na figura 3.8, apresenta-se a representação em isosuperfície de um volume 3D do *phantom* MCAT^{3.7} (UNC) em nove níveis do espaço de escalas. A figura 3.9 apresenta os tempos de processamento para geração do espaço de escalas para esse volume, com resolução de 64 x 64 x 64 pixels. Foram computados os tempos para construção de espaços de escalas com um número crescente de níveis. São apresentados os tempos de processamento em dois servidores distintos: um servidor Sun Ultra Enterprise 450, Ultra4, 2 GB de RAM (CFP 2000 = 11,1), e um servidor Intel(R) Xeon(TM) 2 X CPU 2.80 GHz HyperThreading, 2 GB de RAM (CFP 2000^{3.8} = 13,2 – Hyper Threading technology enabled).

^{3.7} O “Mathematical CARDiac Torso” (MCAT) é um *phantom* antropomórfico, desenvolvido na Universidade da Carolina do Norte, que tem sido utilizado em pesquisa de tomografia por emissão de fótons. Utilizando fórmulas matemáticas, o tamanho, forma e configuração das maiores estruturas torácicas – tais como coração, fígado, pulmões e caixa torácica – são realisticamente modelados para propósito de análise de imagens. (retirado da página da UNC).

^{3.8} Valores obtidos em www.spec.org.

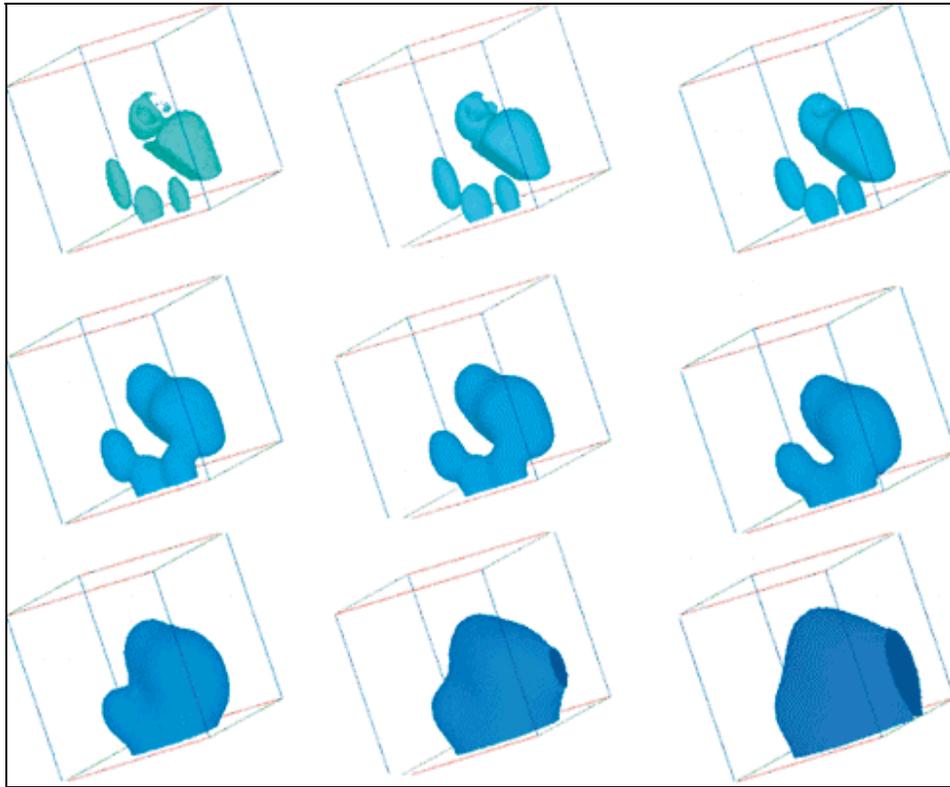


Figura 3.8. Nove níveis do espaço de escalas para o *phantom* MCAT, construído com $\tau = 0,19$. Representação em isosuperfície utilizando o AVS®.

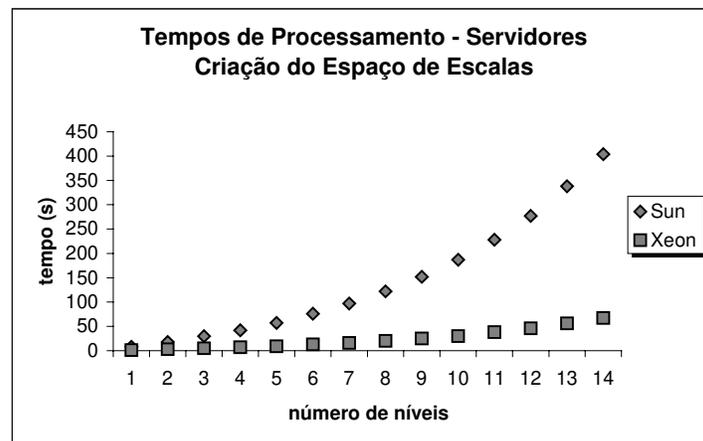


Figura 3.9. Comparação dos tempos de processamento em dois servidores para criação do espaço de escalas com diferentes níveis, para o volume 3D apresentado na figura 3.9. A tabela com os valores dos tempos é apresentada no Apêndice I.

3.8. Detecção de estruturas e representação

A criação do espaço de escalas permite o estabelecimento de uma hierarquia entre as estruturas da imagem, constituindo, desta forma, uma etapa importante entre a representação baseada apenas nos valores dos elementos da imagem e uma descrição mais semântica dos dados. O espaço de escalas linear pode ser considerado, assim, uma representação genérica dos dados de imagem comum para diferentes tipos de processamento, com diferentes finalidades. As principais questões que se apresentam, a partir daí, são como descrever adequadamente a hierarquia ao longo das escalas e como extrair as estruturas de interesse em cada nível do espaço de escalas, de tal forma que seja possível construir uma nova representação dos dados adequada para rotinas de processamento de nível mais alto. Esses tópicos serão abordados no capítulo 4, a seguir.

It is of the highest importance in the art of detection to be able to recognize out of a number of facts which are incidental and which are vital. Otherwise your energy and attention must be dissipated instead of being concentrated.

- Sherlock Holmes

Capítulo 4

Detecção de estruturas e representação em múltiplas escalas

Neste capítulo, será considerado o problema de extração de estruturas para o propósito de identificação de objetos em uma cena, através da utilização de operadores diferenciais. Em particular, será descrito o conceito da estrutura adotada neste trabalho para a representação de informações em imagens, os *blobs*^{4.1}, e formas para sua detecção. A seguir, será apresentada uma representação de dados em múltiplas escalas construídas a partir dessas estruturas, o *Scale Space Primal Sketch*, SSPS. Essa representação foi originalmente proposta por Lindeberg (1993) e seu objetivo é tornar explícitos os blobs e suas relações ao longo das escalas. A idéia central consiste em relacionar estruturas em diferentes escalas no espaço de escalas e transformá-las em objetos com uma ordem a mais, chamados de blobs de espaço de escalas, e extrair características significativas da imagem, baseando-se na aparência e estabilidade desses objetos ao longo das escalas. No final do capítulo, serão apresentados detalhes da implementação e alguns resultados.

^{4.1} Neste texto será mantido o termo inglês, pois não foi encontrada uma tradução adequada para descrever o fenômeno. Como o termo será muito utilizado ao longo do texto, ele não será mais escrito em itálico.

4.1. Operadores para detecção de características de imagem

4.1.1. Introdução

Os objetos em uma cena podem ser descritos de diversas formas, tais como: por suas bordas, pelas suas propriedades geométricas, ou pelas suas áreas. Cada objeto possui uma propriedade característica (intensidade, textura, forma) que, idealmente, o distingue das demais estruturas presentes na cena. Qualquer metodologia para interpretação de imagens envolve a fase de detecção de propriedades características para a geração das imagens segmentadas (Lillholm *et al.*, 2003), descritas no item 2.1.3. A representação deve ser abstrata o suficiente, de tal forma que as características sejam invariantes em relação a transformações (translações, rotações), e que representem invariantes na imagem (Lindeberg, 1993). De acordo com a definição dada por Ter Haar Romeny (1996), as características de imagem podem ser definidas da seguinte forma:

Uma característica de imagem é o conjunto de extremos (máximos e mínimos) de uma função definida em uma imagem.

A partir da definição apresentada, surge a questão de como definir as funções de imagem. Ou de forma equivalente, o que seria uma boa função de imagem? Essa função deve, em princípio, descrever características que tenham significado visual perceptível (Ter Haar Romeny, 1996).

Os primeiros trabalhos nessa linha tinham como objetivo a detecção de bordas (Prewitt^{4.2} 1970, Roberts^{4.3} 1965 *apud* Lindeberg, 1998). As pesquisas demonstraram que é muito difícil extrair bordas de maneira confiável, principalmente devido à sensibilidade ao ruído. Conforme já discutido no capítulo 3, este é um problema intrínseco à operação de diferenciação, normalmente utilizada para a determinação de bordas. A detecção de bordas no espaço de escalas é uma forma de conseguir uma visão mais global da imagem, através de sua análise em níveis diferentes (Lifshitz e Pizer, 1990).

^{4.2} Prewitt, J. M. S. **Object enhancement and extraction.** In: A. Rosenfeld and B. S. Lipkin, editors, *Picture Processing and Psychophysics*, pages 75-149. Academic Press, New York, 1970.

^{4.3} Roberts, L. G. **Machine perception of three-dimensional solids.** In: J. T. Tippet *et al.*, editors, *Optical and Electro-Optical Information Processing*, pages 159-197. MIT Press, Cambridge, Massachusetts, 1965.

O desenvolvimento dessas idéias incentivou diversas pesquisas na avaliação de características de imagens em múltiplas escalas (Lindeberg, 1994; Gauch, 1999; Pizer, 1994; Keshet e Heijmans, 2000). Niessen (1995) apresentou uma abordagem para o cálculo de gradientes em imagens tri-dimensionais utilizando espaços de escalas não lineares. O comportamento de picos e vales em imagens foi estudado por Gauch (1998). Eles foram definidos em termos da geometria diferencial local da imagem (extremos de curvas de nível) no espaço de escalas.

Outra característica que tem sido bastante utilizada para análise de imagens em espaço de escalas é o blob de nível de cinza, que será descrita em detalhes na próxima seção.

4.1.2. Blobs de nível de cinza

Na formulação inicial da teoria do espaço de escalas, Koenderink (1984) identificou regiões mais claras e mais escuras do que o fundo como estruturas importantes da imagem. Essas regiões foram chamadas de blobs claros e escuros e formam estruturas com uma dimensão a mais do que a imagem, quando esta é analisada na dimensão de escalas.

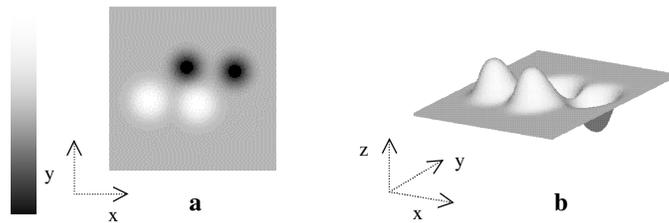


Figura 4.1. (a) Imagem sintética (criada por software desenvolvido neste trabalho) contendo duas estruturas com intensidade maior que o fundo e duas estruturas com intensidade menor, visualizadas em níveis de cinza; (b) Visualização em superfícies de nível da imagem apresentada em a, na qual o valor de intensidade de cada ponto (x,y) determina a coordenada z correspondente. À esquerda da imagem (a) apresenta-se a escala de níveis de cinza: intensidades mais baixas são associadas ao preto e intensidades mais altas são associadas ao branco.

A denominação claro e escuro decorre do fato de que, quando as imagens são apresentadas em tons de cinza, às regiões com maior intensidade são associados tons mais próximos do branco (tons claros) e às regiões com menor intensidade, tons mais próximos do preto (tons escuros), conforme pode ser visualizado na figura 4.1.

Na análise de imagens usando múltiplas escalas, as relações entre as estruturas no espaço de escalas é chamada de estrutura profunda (*deep structure*) da imagem em contraposição à estrutura superficial (*superficial structure*), que descreve as estruturas presentes em um único nível de escala (Koenderink, 1984; Griffin e Colchester, 1995). A associação de regiões mais claras e escuras do que o fundo a estruturas de interesse está relacionada ao fato destas estruturas possuírem uma intensidade (ou faixa de intensidades) que as diferencia de sua vizinhança.

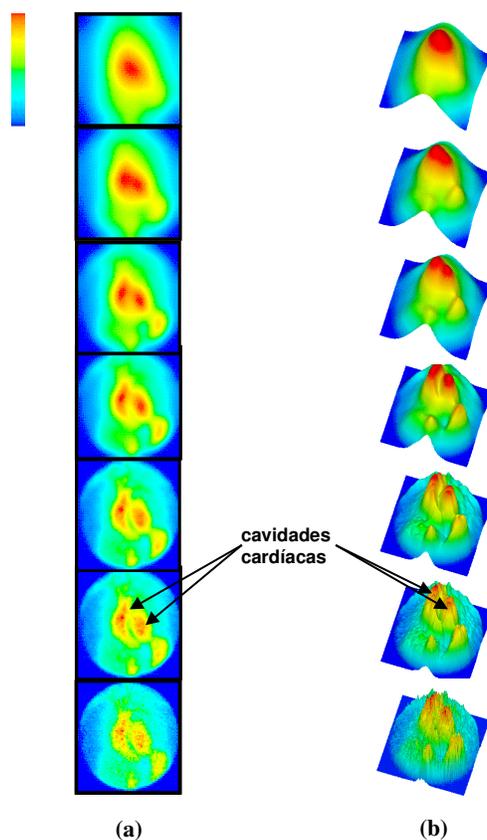


Figura 4.2. (a) Imagem de ventriculografia cintilográfica em um espaço de escalas com 7 níveis. A imagem inferior é a original e as subsequentes são versões suavizadas progressivamente; (b) representação de isosuperfície da imagem mostrada em (a). A tabela de cores é apresentada no canto superior esquerdo. Valores de intensidade mais altos correspondem aos tons de vermelho e os de intensidade mais baixa aos tons de azul. (Imagem obtida no Serviço de Medicina Nuclear e Imagem Molecular do Instituto do Coração – HCFMUSP.)

Além de serem estruturas que se destacam na imagem original, uma característica que os torna muito interessante para análise em múltiplas escalas é o fato de os blobs claros

e escuros tenderem a se manter proeminentes ao longo das escalas. Na figura 4.2, que apresenta o espaço de escalas de uma imagem de ventriculografia cintilográfica, pode-se verificar que as regiões que mais se sobressaem visualmente são aquelas com maior intensidade que o fundo e correspondem às regiões de interesse da imagem (cavidades cardíacas). Essa característica as torna bastante adequadas para elementos de uma representação da imagem englobando todas as escalas.

4.1.3. Definição

O conceito de blob de nível de cinza para imagens bi-dimensionais pode ser definido qualitativamente utilizando-se a idéia de bacias hidrográficas, ou *watershed*, da Morfologia Matemática: supõe-se a função da imagem como uma área geográfica totalmente inundada. À medida em que o nível da água começa a descer, começam a aparecer picos, ou pontos de máximo^{4.4}. Num determinado ponto, as regiões definidas por dois picos se unem em um ponto, chamado ponto de sela^{4.5}. A diferença entre a intensidade do ponto máximo e do ponto de sela define o *contraste* do blob. Esses conceitos são visualizados na figura 4.3.

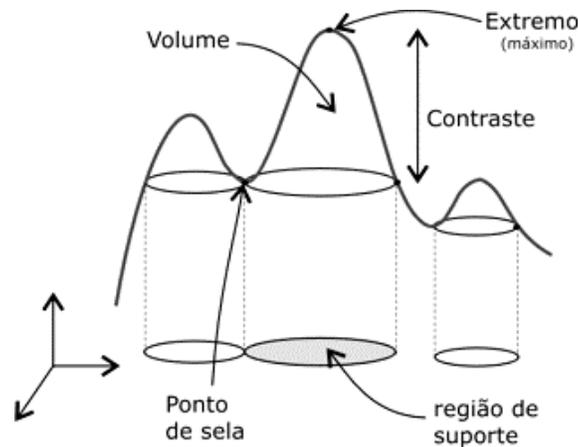


Figura 4.3. Ilustração do conceito de blob de nível de cinza (blob claro). Na figura, são mostrados os pontos relevantes para a determinação do blob: extremos e ponto de sela. Figura extraída de Coulon *et al.* (1997).

^{4.4} O ponto de máximo é um ponto de extremo local, que define um blob claro. Pontos de mínimo local definem blobs escuros.

^{4.5} O ponto de sela é o ponto de encontro entre dois blobs ou entre um blob e o fundo.

O nível de cinza no ponto de sela é chamado de nível de base dos blobs. A região de suporte do blob é definida como aquela que contém os pontos com valores de intensidade maiores do que o nível de base e podem ser atingidos a partir do máximo local sem passar por pontos com valores abaixo do nível de base associado a esse blob. Na figura 4.4.b, são apresentadas as regiões de suporte dos três blobs da figura 4.4.a. Para imagens 2D, o blob de nível de cinza é definido como o volume tri-dimensional delimitado pela superfície de nível de cinza e o nível de base. As figuras 4.4.d e 4.4.e mostram os blobs de nível de cinza da figura 4.4.a e 4.4.b. O volume tri-dimensional do blob de nível de cinza é uma medida do contraste e da extensão espacial (linha de base) do blob. Geometricamente, os blobs de nível de cinza (GLBlobs) podem ainda ser interpretados como regiões elípticas da imagem associadas a um ponto de extremo (máximo ou mínimo) que se estendem até cruzar com um ponto de inflexão ou ponto de sela.

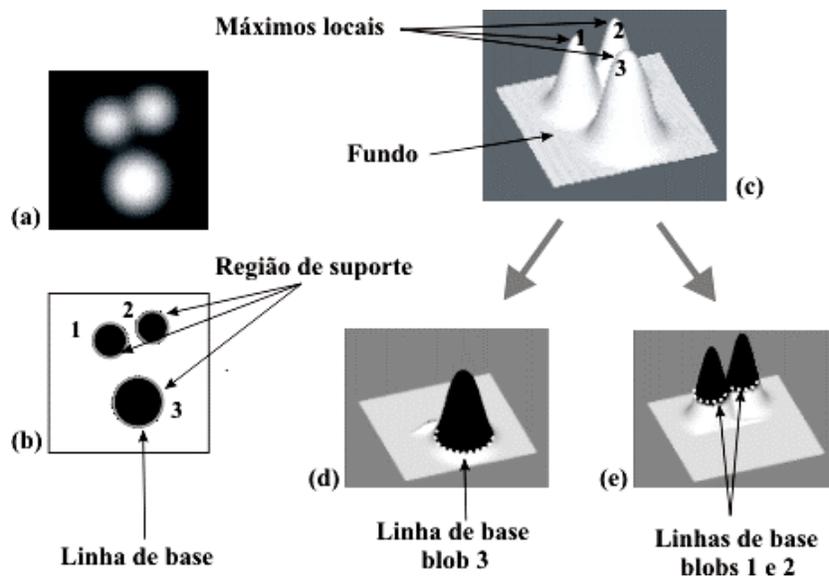


Figura 4.4. (a) Imagem sintética (criada por software desenvolvido neste trabalho) contendo três estruturas com intensidades maiores que o fundo. (b) Regiões de suporte e as linhas de base. (c) Visualização em isosuperfície da imagem (a), mostrando os três máximos locais, que são o ponto de partida para delimitação dos blobs. Em (d) e (e), são apresentados os três blobs extraídos da imagem (c). Nestas figuras pode-se visualizar o conceito de blob de nível de cinza para uma imagem 2D: uma estrutura tridimensional que, a partir de uma máximo local se estende até encontrar um ponto de inflexão. Os volumes apresentados em preto nas figuras (d) e (e) representam o volume do blob. A representação em isosuperfície utilizada em (c), (d) e (e) foi obtida utilizando o software AVS®.

Os conceitos apresentados, expressos em termos de sinais contínuos bi-dimensionais, podem ser estendidos para qualquer dimensão, bem como para dados discretos. A definição apresentada acima foi para máximos locais. Mínimos locais são tratados de forma análoga, e cada mínimo local cria um blob escuro em um fundo claro.

4.1.4. Propriedades

Os blobs são determinados diretamente a partir das propriedades topológicas da imagem. Eles não são estruturas puramente locais, como os extremos, mas regionais. Uma propriedade inerente a esta definição é que ela leva a uma competição entre estruturas. A presença de um outro blob próximo tende a neutralizar um blob ou a reduzir o seu tamanho. Em outras palavras, as estruturas se manifestam apenas de forma relativa em relação ao fundo.

4.1.5. Motivação para uma hierarquia em múltiplas escalas

Assim como outras propriedades características de imagem, o blob de nível de cinza em um único nível de escala não é suficientemente poderoso para a extração de estruturas estáveis (Lindeberg 1993). Os blobs são extremamente sensíveis a ruídos, pois segundo a sua definição, dois extremos locais próximos tendem a neutralizar os blobs associados. Assim, um pico de grande amplitude distorcido pela superposição de alguns extremos locais de baixa amplitude pode não ser detectado como um único blob. Apenas os blobs de escala baixa são detectados.

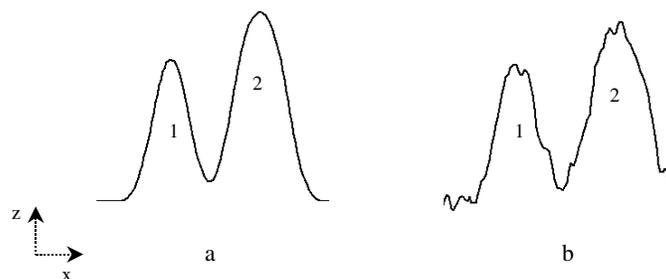


Figura 4.5. (a) Dois picos de alto contraste em um sinal 1D. (b) Aos picos iniciais 1 e 2 são superpostos picos de escalas menores. Os picos iniciais 1 e 2 não são mais detectados como blobs únicos, se considerados em uma única escala. Figura retirada de Lindeberg (1993)

Na figura 4.5, pode-se visualizar esse efeito em um sinal uni-dimensional: a figura 4.5.a apresenta um sinal no qual estão presentes dois picos de alta escala, que constituem dois blobs distintos. Na figura 4.5.b, foram acrescentadas informações de baixa escala (ruído) que se superpõem ao sinal original, fazendo com que os picos originais 1 e 2 não constituam mais blobs únicos. Desta maneira, para se obter descritores mais estáveis, é natural analisar o comportamento dos blobs de nível de cinza no espaço de escalas.

4.1.6. Blobs de espaço de escalas

Existe uma certa faixa finita de escalas para as quais um determinado blob que representa uma estrutura de imagem pode ser identificado. Em uma faixa ainda mais limitada de escalas, a estrutura é representada por um único blob, sem articulações, ou pequenos detalhes, que fazem com que ele se subdivida em outros blobs. Em escalas muito baixas (como na imagem original), é difícil detectar qualquer blob que represente estruturas relevantes na imagem, pois eles estão associados a pequenos detalhes e a ruído. Por outro lado, em escalas muito altas, os blobs relevantes perdem a identidade, fundindo-se a outras estruturas próximas, devido ao processo de difusão. Desta forma, há uma faixa limitada de escalas na qual se pode afirmar que uma estrutura existe. A figura 4.6 exemplifica esse conceito. Em 4.6.a e b, é apresentada uma imagem contendo 3 estruturas. Em 4.6.c, os blobs que representam as três estruturas são visualizados em diversas escalas. Observa-se, que as estruturas são representadas por blobs distintos nos níveis 1, 2 e 3. No nível 0 (imagem original), as estruturas estão dispersas em diversos blobs, devido ao ruído. No nível 4, os blobs representando as estruturas 1 e 2 se fundem, e no nível 5 todos os blobs se fundem.

Em imagens médicas, essas propriedades refletem o fato de que, em escalas muito baixas, os blobs não apresentam nenhuma correlação anatômica ou funcional, pois são estruturas relacionadas basicamente ao ruído presente em todas as modalidades médicas. À medida que se sobe no espaço de escalas, os blobs representativos das estruturas presentes na imagem começam a se manifestar, conforme pode ser observado na imagem por ressonância magnética do tórax, apresentada na figura 4.7. Nessa figura, os blobs escuros, que se manifestam nos níveis mais alto, representam estruturas anatômicas da imagem: pulmões, artérias, veias e cavidades cardíacas.

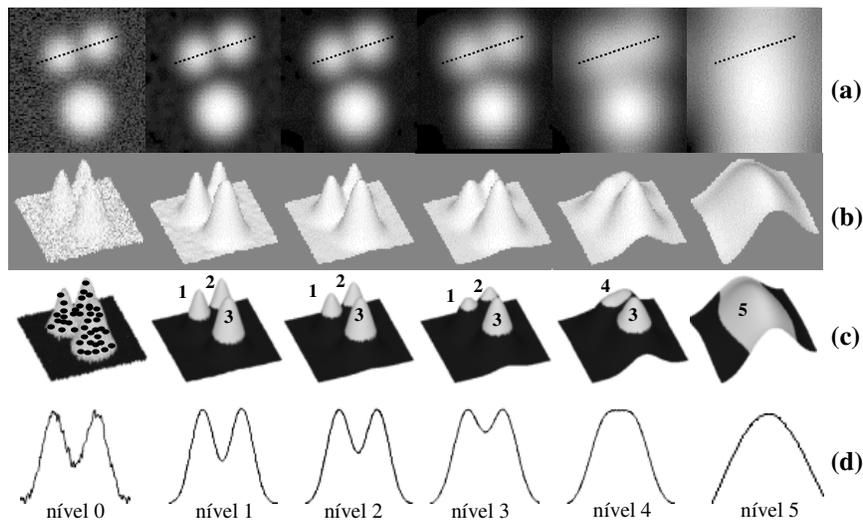


Figura 4.6. (a) Seis escalas da imagem sintética apresentada na figura 4.4.a. (b) Visualização das figuras em isosuperfície. (c) Visualização dos blobs (assinalados em branco) nas diversas escalas. Pode-se observar que os blobs 1 e 2 vão se aproximando até que, na escala 4, eles se agrupam para formar um novo blob. Na escala 5, esse novo blob vai se agrupar com o blob 3. (d) Visualização dos efeitos descritos em (c) para os blobs 1 e 2 em curvas de intensidade em função da posição, para as linhas mostradas em (a).

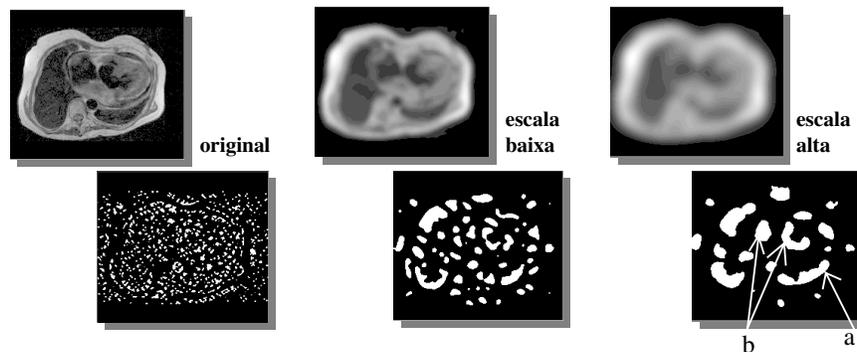


Figura 4.7. Blobs de nível de cinza extraídos de uma imagem torácica obtida por ressonância magnética. Na linha superior, a imagem é apresentada em três níveis do espaço de escala. Os GLBlobs extraídos a partir de cada uma dessas imagens são apresentados na linha inferior. Na imagem original os blobs escuros refletem principalmente o ruído presente na imagem. Na imagem de escala baixa começam a aparecer as estruturas anatômicas representadas pelos blobs (pulmões, artérias, veias e cavidades cardíacas), porém ainda formadas por estruturas desconexas. Na escala alta os blobs formam estruturas puras: pode-se distinguir, por exemplo, parte do pulmão esquerdo (a) e cavidades cardíacas (b). GLBlobs extraídos usando as expressões 4.4, 4.6 e 4.7. (Imagem adquirida no Serviço de Ressonância Magnética – Divisão de Diagnóstico por Imagem - Instituto do Coração – HCFMUSP).

Como o objetivo é construir uma representação que descreva o comportamento da imagem ao longo do espaço de escalas, é necessário acompanhar os blobs de nível de cinza ao longo das escalas. Para cada blob em um determinado nível de escala, geralmente existem blobs correspondentes nas escalas imediatamente acima e abaixo. Para determinar esses blobs correspondentes, utiliza-se um critério para o casamento dessas estruturas, normalmente baseado na idéia de que a região de suporte do blob da escala inferior deve estar contida na região de suporte do blob da escala superior.

Entretanto, nem sempre é possível encontrar blobs de nível de cinza correspondentes em escalas distintas, pois as estruturas não existem em todos os níveis de escala e tendem a desaparecer nos níveis mais altos. Quando a correspondência entre um blob de nível de cinza e outro blob em escalas superiores ou inferiores deixa de existir, diz-se que ocorreu um *evento de blob*. A análise teórica do comportamento de pontos de extremos e de sela feita por Lindeberg (Lindeberg^{4,6} 1994 *apud* Coulon *et al.*, 1997), levou à classificação dos eventos de blobs em quatro tipos, que podem ser visualizados na figura 4.8:

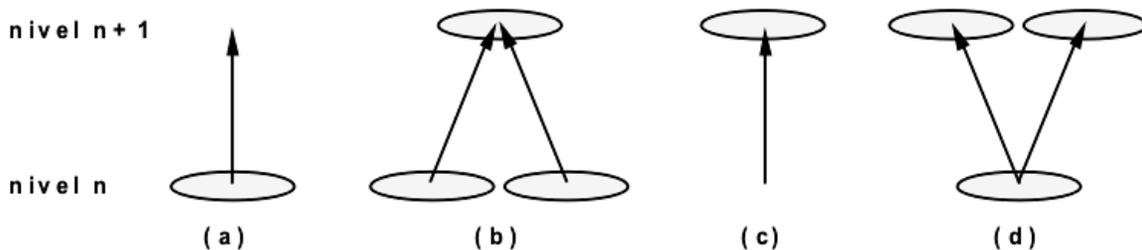


Figura 4.8. Tipos de eventos de blobs: (a) aniquilação; (b) acoplamento; (c) criação; (d) separação. Figura retirada de Coulon *et al.* (1997).

- aniquilação: um blob desaparece;
- acoplamento: dois blobs se unem em um;
- criação: um novo blob aparece;
- separação: um blob se divide em dois.

^{4,6}Lindeberg, T. **Scale space theory in computer vision**. Kluwer Academic, 1994.

Os eventos de blob são chamados de bifurcações. Um blob de espaço de escalas (SSBlob) é definido como o objeto produzido pela união dos blobs de nível de cinza (GLBlob) correspondentes entre duas bifurcações (Coulon *et al.* 1997). Por exemplo, na figura 4.6, o SSBlob 1 é formado pela união dos GLBlobs dos níveis 1, 2 e 3 .

4.2. A representação de *primal sketch*

4.2.1. *Primal Sketch*

A descrição simplificada da imagem, como aquela encontrada na representação de imagens segmentadas - que podem apresentar, por exemplo, bordas ou blobs da imagem - facilita a tarefa de identificação de objetos na imagem (Beaudet^{4.7} *apud* Lei, 1999). Marr foi o primeiro a propor uma representação utilizando a descrição baseada em bordas, a qual chamou de *Primal Sketch* (Marr^{4.8} 1976 *apud* Marr e Hildreth, 1980), e que é formada por duas partes. Primeiro, é feita uma descrição para as variações de intensidade da imagem, usando características como segmentos de borda, blobs ou extremidades. Essa descrição foi chamada por Marr (1980) de *raw primal sketch*. Depois, numa segunda fase, as relações geométricas entre os elementos do *raw primal sketch* são tornadas explícitas, e uma descrição mais abstrata é construída pelo seu agrupamento ao longo das diversas escalas^{4.9}. A hierarquia resultante foi chamada por Marr de *full primal sketch*. O desenvolvimento do conceito de *Primal Sketch* feito por Marr foi inspirado nas informações sobre o sistema visual dos mamíferos.

4.2.2. *Scale Space Primal Sketch* ou árvore de bifurcação

Baseado nos conceitos da estrutura de *primal sketch*, elaborada por Marr, e posteriormente utilizada no estudo de espaços de escalas lineares feitos por Koenderink (1984), Lindeberg (1993) propôs uma estrutura para representação da imagem que é uma

^{4.7}Beaudet, P.R. **Rotational invariant image operators**. In: Proc. of the Int. Conf. on Pattern Recognition, 579-583, 1978.

^{4.8}Marr, D. **Early processing of visual information**. Phil. Trans. R. Soc. Lond. B275, 483-521, 1976.

^{4.9}O conceito de escala apresentado por Marr em 1980 já continha alguns elementos que viriam a fazer parte da Teoria de Espaço de Escalas, porém o desenvolvimento formal desta teoria seria feito somente alguns anos depois.

árvore que descreve os eventos de blobs no espaço de escalas, como a visualizada na figura 4.9. Nessa figura, apresentam-se os eventos para o espaço de escalas da figura 4.6. A partir da construção da estrutura de árvore relacional para os blobs de espaço de escalas, cada blob de espaço de escalas está associado a uma escala máxima, chamada de escala de aparecimento t_A , e a uma escala mínima, chamada de escala de desaparecimento t_D . A diferença entre a escala de desaparecimento e a escala de aparecimento fornece o tempo de vida do blob. Nos eventos de acoplamento e separação, os blobs existentes antes da bifurcação são encarados como blobs de espaço de escalas diferentes daqueles blobs de nível de cinza que existem após a bifurcação. A árvore que representa as relações entre os SSBlobs é chamada de árvore de espaço de escalas ou árvore de bifurcação.

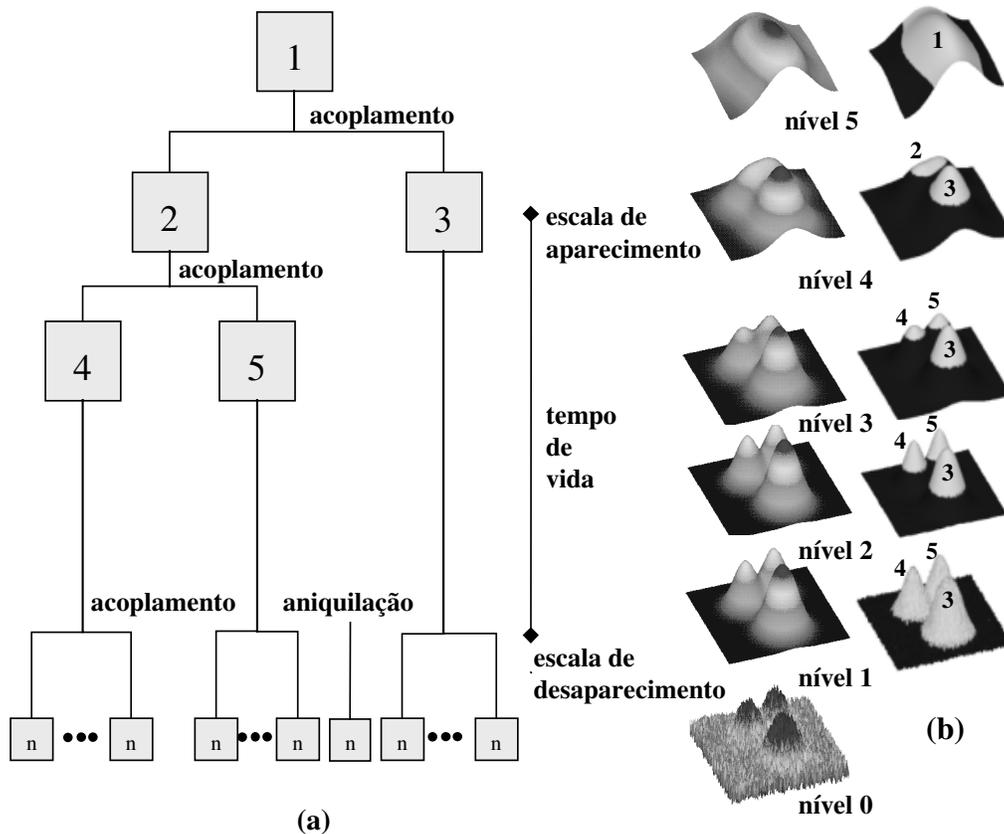


Figura 4.9. Exemplo de estrutura de árvores para o espaço de escalas mostrado em 4.6.a. Entre os níveis 0 (imagem original) e 1 ocorrem diversos eventos de blob: muitas aniquilações e acoplamentos, os quais vão formar os blobs 3,4,5. Para a construção do SSPS, a análise é iniciada na escala mais alta e por isso, os números dos SSBlobs são diferentes em relação àqueles da figura 4.6.

Cada nó da árvore representa um blob de espaço de escalas. Para que a árvore possa ser utilizada na análise da imagem, os nós devem conter informações relevantes sobre as estruturas representadas. No caso da análise utilizando SSBlobs, essas informações incluem as escalas de aparecimento e desaparecimento, o tempo de vida, os blobs de nível de cinza que o formam, os fenômenos de criação e destruição, os blobs imediatamente acima e abaixo no espaço de escalas que se relacionam a ele e seu volume no espaço de escalas, que é dado pela soma dos volumes de seus blobs de nível de cinza. A árvore contendo essas informações foi chamada de *Scale Space Primal Sketch* (SSPS).

4.2.3. Medidas de relevância dos SSBlobs

A proposta original do trabalho descrito por Lindeberg (1993) era descrever agrupamentos presentes na imagem a partir da análise dos eventos do SSPS. O seu principal objetivo era determinar os blobs de espaço de escala mais significativos (os quais representam regiões importantes na imagem), seu tempo de vida e a escala nas quais ele se manifesta com maior evidência, a partir da análise de características da estrutura. Para atingir esses objetivos, o autor partiu de algumas suposições. A principal suposição feita em sua abordagem era a seguinte:

Estruturas significativas no espaço de escalas devem corresponder a estruturas significativas na imagem.

Essa suposição pode ser aplicada a outras estruturas além dos blobs. Mais precisamente, as suposições feitas acerca do comportamento dos blobs de espaço de escalas eram as seguintes (Lindeberg, 1993):

Suposição 1: classificação dos blobs baseada em sua relevância

Na ausência de outras evidências, um blob de espaço de escalas com valor de volume alto provavelmente corresponde a uma região de blob relevante na imagem.

Suposição 2: seleção da escala

Na ausência de outras evidências, a escala na qual o blob de espaço de escalas apresentar o volume máximo, provavelmente corresponde a uma escala relevante para a representação desse blob.

Suposição 3: seleção da extensão espacial do blob

Na ausência de outras evidências, a extensão espacial do blob de espaço de escalas pode ser representada pela região de suporte no nível de escalas selecionado de acordo com a suposição 2.

4.2.4. Extração de estruturas importantes da imagem

Com base na suposição 1, apresentada no item anterior, Lindeberg definiu um parâmetro de significância para os SSBlobs em função do seu volume total, que é a soma das intensidades na região de suporte de todos os GLBlobs que o compõem. De acordo com esta proposta, as estruturas presentes na imagem são classificadas segundo a sua relevância, atribuída em função do volume do SSBlob. De forma geral, a metodologia proposta por Lindeberg pode ser descrita pelos seguintes passos:

- Gerar a estrutura de *primal sketch* de espaço de escalas, na qual os blobs são extraídos em todos os níveis de escala analisados e associados ao longo das escalas em blobs de espaço de escalas;
- Calcular o volume total para cada SSBlob;
- Ordenar os blobs de espaço de escala em ordem decrescente de sua relevância, dada em função do volume;
- Para cada blob de espaço de escalas, determinar a escala na qual ele assume o maior volume de blob de espaço de escala, e extrair a região de suporte nessa escala.

4.2.5. Considerações sobre a utilização do SSPS

Lindeberg (1993) aplicou a metodologia apresentada a cenas contendo objetos do mundo real para extração de estruturas relevantes na imagem. Utilizou também outras

características da imagem, como junções, na análise da metodologia. Coulon *et al.* (1997) utilizaram o SSPS para caracterização de ativações cerebrais em imagens de Tomografia por Emissão de Póstron. Em seu trabalho, eles propuseram uma modificação à proposta original de *Primal Sketch*, para diminuir o efeito da sensibilidade a ruído na definição dos blobs de nível de cinza na construção do SSPS. A figura 4.10 (esquerda) apresenta um evento de acoplamento de um blob de grande extensão, que representaria um objeto da imagem, com um blob pequeno, que seria ruído. O blob maior fará parte de dois SSBlobs, diminuindo a significância do objeto representado por ele. Os autores propuseram, então, um *pruning* na árvore de SSBlobs, de forma a tornar o evento de acoplamento uma aniquilação do pequeno blob.

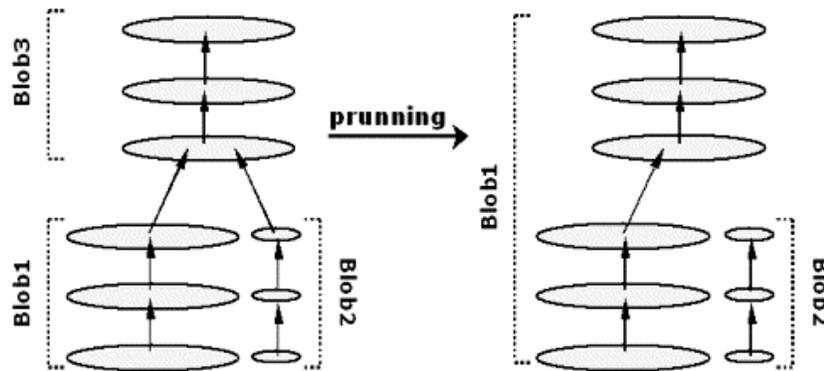


Figura 4.10. Exemplo de *pruning* da árvore de SSBlobs. Figura retirada de Coulon *et al.* (1997)

Em seu trabalho, Coulon ainda analisou a utilização de outros parâmetros para determinação do valor de significância do SSBlob: contraste, região de suporte e amplitude máxima.

4.2.6. Considerações sobre a utilização do SSPS neste trabalho

A abordagem utilizada neste trabalho é diferente daquelas dos dois autores citados. O ponto mais importante é o SSPS não ser utilizado como um método de processamento para determinar estruturas importantes na imagem. Ele é uma estrutura de imagem utilizada, primeiramente, para construção de padrões de objetos conhecidos em uma imagem. A partir do padrão, os objetos são identificados em novas imagens pelo casamento de estruturas

simbólicas, definidas na estrutura de dados. Para esse fim, será feita a análise de inclusão de informações *a priori* sobre os elementos procurados na imagem na estrutura do SSPS.

As mudanças metodológicas propostas por Coulon não são utilizadas neste trabalho para construção do SSPS. A eliminação de um evento de acoplamento de uma estrutura grande com outra pequena pressupõe que uma estrutura grande é mais importante do que a estrutura menor. Neste trabalho, não são feitas pressuposições tão fortes na fase de construção da estrutura de dados. Em escalas baixas, não é possível saber se um blob muito pequeno representa ruído ou se é uma parte desconexa do objeto a ser identificado. Utiliza-se um critério para desconsiderar um blob que seja muito pequeno, baseado na suposição de que não existe resolução em subpixel. Embora nas escalas mais altas seja mantida a resolução inicial para fins de visualização, a escala interna real aumenta a cada nível do espaço de escalas. Desta forma, blobs cujas dimensões forem menores do que a escala interna do nível, que está relacionada com o valor de σ no qual ele se encontra, não são considerados para a construção do SSPS.

O que se busca, na presente abordagem, é definir um modelo, ou padrão, a partir das relações no SSPS e de conhecimento *a priori* sobre as estruturas procuradas. Como o objetivo é utilizar o SSPS como uma estrutura de dados, não é pressuposto desconhecimento do tipo de imagem analisada, pois considera-se que informações importantes podem estar sendo suprimidas. Assim, as suposições apresentadas no item 4.2.3 não serão adotadas.

4.3. Implementação

4.3.1. Operadores utilizados para detecção de blobs

Para a construção da estrutura de dados proposta é necessário um mecanismo para extração dos blobs nas imagens de cada nível. Lindeberg (1993) determinou essas regiões utilizando o operador *watershed* de morfologia matemática. Neste trabalho, entretanto, optou-se por utilizar a definição formal do conceito de blob para a sua determinação: uma região elíptica associada a um extremo que se estende até encontrar um ponto de inflexão.

Conforme discutido no capítulo 3, qualquer propriedade da imagem com significado geométrico pode ser representada por um operador diferencial adequado. Em seu trabalho,

que analisa a relação entre escalas e as estruturas diferenciais de imagens, Florack (1992) descreve um operador para detecção de regiões elípticas na imagem, o operador *umbilicity*. Em coordenadas *manifest invariant*^{4.10}, esse operador foi definido como:

$$U = \frac{\varepsilon_{ij}\varepsilon_{kl}L_{ik}L_{jl}}{L_{mn}L_{nm}}, \text{ onde } \varepsilon_{ij} \text{ é o tensor de Levi-Civita} \quad (4.1)$$

O tensor de Levy-Civita é definido como o operador anti-simétrico:

$$\varepsilon_{i\dots D} = \begin{cases} 1 & \text{se } (1 \dots D) \text{ é uma permutação par de } 1\dots D \\ -1 & \text{se } (1 \dots D) \text{ é uma permutação ímpar de } 1\dots D \\ 0 & \text{outro caso} \end{cases}$$

Do cálculo tensorial, tem-se a relação entre o tensor de Levi-Civita e o tensor de Kronecker δ_{ij} :

$$\varepsilon_{ij}\varepsilon_{kl} = \delta_{ik}\delta_{jl} - \delta_{il}\delta_{jk} \quad (4.2)$$

O tensor de Kronecker é definido como o operador de simetria $\varepsilon_{i,j} = \begin{cases} 1 & \text{se } i=j \\ 0 & \text{outro caso} \end{cases}$.

Substituindo (4.2.) em (4.1)

$$\frac{\delta_{ik}\delta_{jl}L_{ik}L_{jl} - \delta_{il}\delta_{ik}L_{ik}L_{jl}}{L_{ij}L_{ji}} = \frac{L_{ii}L_{jj} - L_{ij}L_{ji}}{L_{ij}L_{ji}} \quad (4.3)$$

Em coordenadas cartesianas, tem-se

$$L_{xx} = \frac{\partial^2}{\partial x^2}; \quad L_{yy} = \frac{\partial^2}{\partial y^2}; \quad L_{zz} = \frac{\partial^2}{\partial z^2}$$

$$L_{xy} = L_{yx} = \frac{\partial^2}{\partial x \partial y}; \quad L_{xz} = L_{zx} = \frac{\partial^2}{\partial x \partial z}; \quad L_{yz} = L_{zy} = \frac{\partial^2}{\partial z \partial z}$$

Para o cálculo em 2D, do numerador de U :

^{4.10} A notação de coordenadas *manifest invariant* segue a convenção de soma de Einstein. Por exemplo, em 2D: $L_i L_i \equiv \sum_{i=x,y}^D L_i L_i = L_x^2 + L_y^2$, ou $L_{ii} \equiv \sum_{i=x,y}^D L_{ii} = L_{xx} + L_{yy}$ e $L_{ij} \equiv \sum_{i=x,y}^D \sum_{j=x,y}^D L_{ji}$

$$\left. \begin{array}{l} i = x; j = x \Rightarrow U_{num} = L_{xx}L_{xx} - L_{xx}L_{xx} \mapsto 0 \\ i = x; j = y \Rightarrow U_{num} = L_{xx}L_{yy} - L_{xy}L_{yx} \\ i = y; j = x \Rightarrow U_{num} = L_{yy}L_{xx} - L_{yx}L_{xy} \\ i = y; j = y \Rightarrow U_{num} = L_{yy}L_{yy} - L_{yy}L_{yy} \mapsto 0 \end{array} \right\} \rightarrow$$

$$U_{num} = L_{xx}L_{yy} - L_{xy}L_{yx} + L_{xx}L_{yy} - L_{xy}L_{yx} = 2(L_{xx}L_{yy} - L_{xy}L_{yx})$$

$$U_{2D} = \frac{2(L_{xx}L_{yy} - L_{xy}L_{yx})}{L_{xx}^2 + 2L_{xy}L_{yx} + L_{yy}^2} \quad (4.4)$$

De forma análoga, chega-se à expressão para 3D:

$$U_{3D} = \frac{2(L_{xx}L_{yy} + L_{xx}L_{zz} + L_{yy}L_{zz} - L_{xy}L_{yx} - L_{xz}L_{zx} - L_{yz}L_{zy})}{L_{xx}^2 + L_{yy}^2 + L_{zz}^2 + 2(L_{xy}L_{yx} + L_{xz}L_{zx} + L_{yz}L_{zy})} \quad (4.5)$$

As regiões com valores positivos do operador *umbilicity* são os blobs de nível de cinza. Para diferenciar os tipos de blobs em uma imagem aplica-se o operador laplaceano:

$$L = \frac{\partial^2}{\partial x^2} + \frac{\partial^2}{\partial y^2} + \frac{\partial^2}{\partial z^2} \quad (4.6)$$

A discriminação é feita utilizando o seguinte critério:

$$\left\{ \begin{array}{l} U > 0 \text{ e } L > 0 \Rightarrow \text{blob escuro} \\ U > 0 \text{ e } L < 0 \Rightarrow \text{blob claro} \end{array} \right. \quad (4.7)$$

4.3.2. Linguagem de programação e ferramentas de desenvolvimento

As rotinas para detecção dos blobs de nível de cinza e para criação do *scale space primal sketch* foram implementadas em Ansi C. Para a detecção dos blobs de nível de cinza foi implementada a rotina computacional *createBlobs* e para a criação do SSPS foi implementada a rotina *primalTree*. Ambos os itens de software usam a biblioteca *libscale*, descrita no capítulo 3. Os resultados apresentados no item 4.4 foram obtidos em um servidor Sun® Ultra Enterprise 450, Ultra4, 2GB de RAM.

4.3.3. Estruturas de dados

A partir das descrições de blobs de nível de cinza e para os blobs de espaço de escalas, foram definidas as seguintes estruturas de dados:

Estruturas de dados para blobs

```
typedef struct Blob_graylevel
{
    int    bvalue;
    int    xmin, ymin, zmin;
    int    xmax, ymax, zmax;
    int    abscale;
    int    int_max, int_base, sup_region;
    float  cgeom_x, cgeom_y, cgeom_z;
    float  veff;
} GLBLOB;
```

bvalue: valor do label do blob na imagem de GLBlobs;

[xmin, ymin, zmin, xmax, ymax, zmax]:

delimitam a região da imagem na qual o blob está inserido;

abscale: escala do blob;

int_max: intensidade máxima dos elementos no blob;

int_base: intensidade média dos elementos na base do blob;

sup_region: número de elementos que compõem o blob;

[cgeom_x, cgeom_y, cgeom_z]:

coordenadas do centro geométrico do blob;

veff: volume efetivo do blob

$$V_{eff} = V_{trans}(G_{volume}; t) = \begin{cases} 1 + V_{prel} & \text{se } V_{prel} \geq 0 \\ \exp(V_{prel}) & \text{nos outros casos} \end{cases} \quad (4.8)$$

$$V_{prel} = \frac{G_{volume} - V_m(t)}{V_\sigma(t)} \quad (4.9)$$

G_{volume} é o volume do blob de nível de cinza (Σ dos valores dos elementos do blob)

V_m é o valor médio de *sup_region* de blobs de imagens de ruído branco na escala n

V_σ é o desvio padrão de *sup_region* de blobs de imagens de ruído branco

```
typedef struct Blob_scalespace
{
    int    tlife;
    int    appscale, disapscale;
    int    creafenom, destfenom;
    int    nglblobs;
    GLBLOB *glblob;
```

```

    int          nblobsant;
    int          *blobsant, blobspos;
    int          volumeSSBlob;
} SSBLOB;

```

tlife: tempo efetivo de vida do blob;

appscale: escala de aparecimento do blob;

disapscale: escala de desaparecimento do blob;

creafenom: fenômeno que gerou a criação do blob:

GROW: aparece em uma escala sem prévia existência

MERGE: aparece como resultado da união de blobs na escala anterior

destfenom: fenômeno que gerou a destruição do blob:

UPPER: não é destruído, existe até à última escala

JOIN: une-se a outros para formar um novo blob em escala superior

NODEF: fenômeno de criação/destruição não definido

ngblobs: número de blobs de nível de cinza que compõem o SSBlob;

gblob: blobs de nível de cinza que compõem o SSBlob;

nblobsant: número de blobs na escala anterior que foram unidos no presente blob;

blobsant: identificadores dos blobs de nível de cinza anteriores;

blobspos: identificador do blob de nível de cinza posterior;

volumeSSBlob: volume do SSBlob, dado por:

$$\sum_{i=0}^n V_{eff}(i) \quad i = 0, 1, \dots, n \quad \text{é a escala do espaço de escalas.} \quad (4.10)$$

Estruturas de Dados para as listas e filas

As listas e filas utilizadas no software *primalTree* são definidas da seguinte forma. Na fila deverão estar contidos os dados de GLBLOB. A estrutura nó para a fila (QNODEPTR) foi definida com o campo de informação contendo um elemento do tipo GLBLOB e um ponteiro para o próximo elemento da fila.

```

typedef struct qnode
{
    GLBLOB      info;
    struct qnode *next;
} *QNODEPTR;

```

A estrutura *fila* (QUEUE) foi implementada contendo dois ponteiros, início e fim da fila, e o número de elementos na fila.

```
typedef struct queue
{
    QNODEPTR    front, rear;
    int         num;
} QUEUE;
```

A lista foi definida com o campo de informações sendo um ponteiro para uma fila do tipo QUEUE e com um ponteiro para o próximo elemento.

```
typedef struct lnode
{
    QUEUE      *quinfo;
    struct lnode *next;
} *LNODEPTR;
```

4.4. Resultados

4.4.1. Tempos de processamento

A figura 4.11 apresenta os tempos de processamento, para obtenção dos GLblobs, utilizando o software *createblobs*, nos níveis do espaço de escalas da imagem 2D sintética, apresentada na figura 3.7 do capítulo 3, em três resoluções distintas, obtidas por interpolação: 64 x 64, 128 x 128 e 256 x 256 pixels. Utilizou-se o valor de $\tau=0,19$.

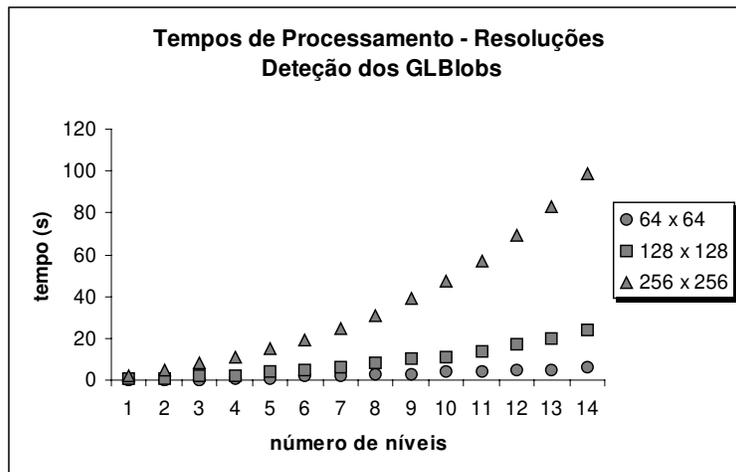


Figura 4.11. Tempos de processamento para obtenção dos GLblobs em espaços de escalas com diferentes níveis, para a imagem apresentada na figura 3.7 (capítulo 3), em três resoluções: 64 x 64, 128 x 128 e 256 x 256 pixels, $\tau=0,19$. A tabela com os valores dos tempos é apresentada no apêndice I. Tempos obtidos no servidor Sun Ultra Enterprise 450.

Na figura 4.12, são mostrados os tempos de processamento para obtenção dos blobs de nível de cinza para espaços de escalas com diferentes números de níveis do *phantom* MCAT, apresentado na figura 3.9 do capítulo 3. São apresentados os tempos obtidos em dois servidores, um servidor Sun® Ultra Enterprise 450, Ultra4, 2 GB de RAM (CFP 2000 = 11,1), e um servidor Intel® Xeon™ 2 X CPU 2.80 GHz HyperThreading, 2 GB de RAM (CFP 2000^{4.11} = 13,2 – Hyper Threading technology enabled).

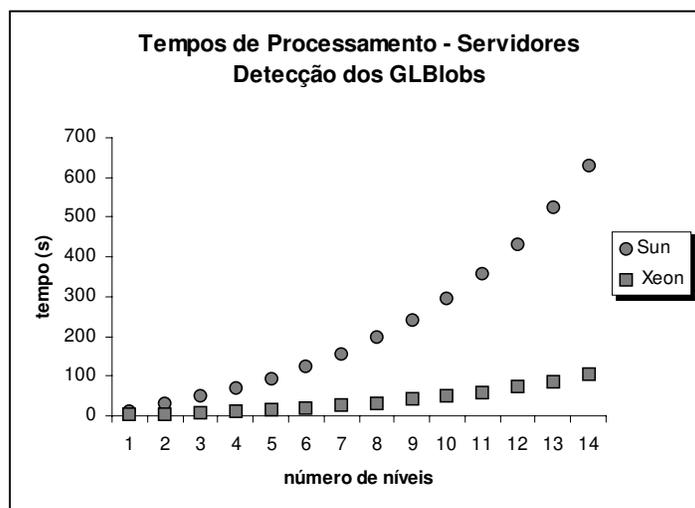


Figura 4.12. Comparação dos tempos de processamento em dois servidores para detecção dos GLBlobs em espaços de escalas com diferentes níveis, para o volume 3D do *phantom* MCAT apresentado na figura 3.9. A tabela com os valores dos tempos é apresentada no apêndice I.

4.4.2. Imagem 3D

A seguir serão apresentados os resultados obtidos na detecção de GLBlobs do volume 3D do *phantom* MCAT. Na figura 4.13, apresentam-se os GLBlobs 3D detectados em 12 níveis do espaço de escalas para o *phantom* MCAT (resolução espacial da imagem original 64 x 64 x 64 e $\tau = 0.19$). Para observar melhor o efeito das escalas na visualização dos GLBlobs, foram escolhidos dois cortes no volume, cujos conjuntos de GLBlobs são apresentados na figura 4.14. Na figura 4.14.a, mostra-se um corte na altura do fígado e na figura 4.14.b, um corte na altura do miocárdio.

^{4.11} Valores obtidos em www.spec.org.

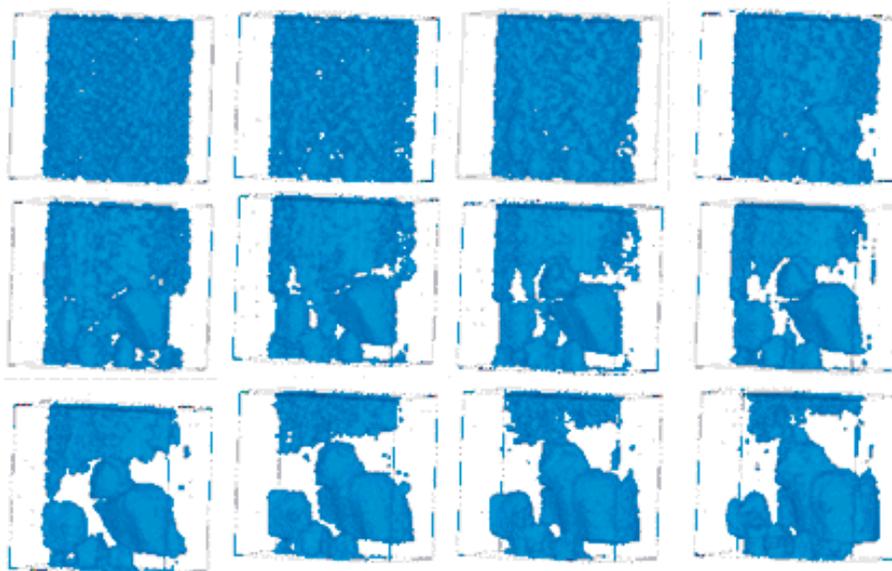


Figura 4.13. Visualização em isosuperfície dos GLBlobs detectados em 12 níveis do espaço de escalas para o volume do *phantom* MCAT, $\tau=0,19$.

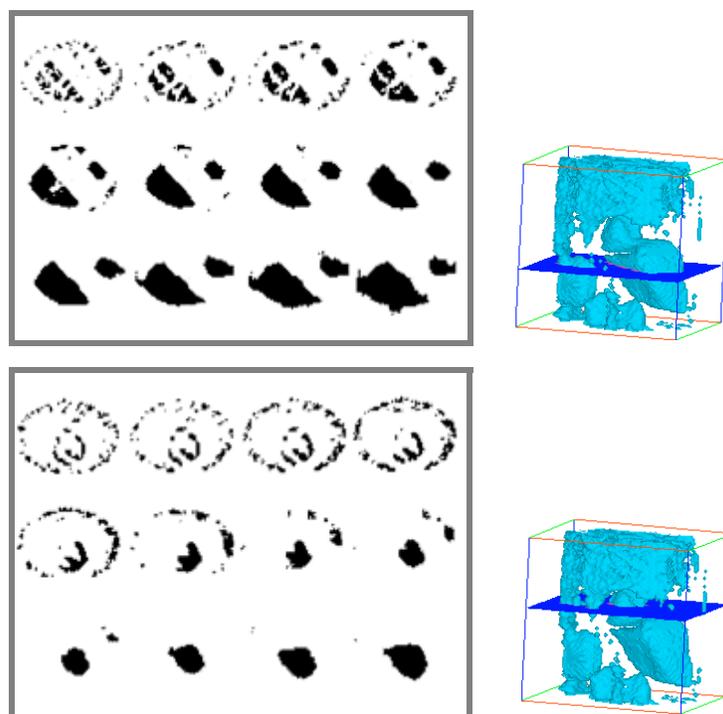


Figura 4.14. Visualização dos GLBlobs do *phantom* MCAT em várias escalas, para dois cortes distintos do volume. Os volumes à direita mostram a posição, no *phantom*, dos cortes apresentados.

4.4.3. Imagem 2D de ressonância magnética

Utilizando-se as expressões 4.4. e 4.6 e as relações 4.7, foram obtidos os blobs escuros para um corte de volume de tórax por ressonância magnética, apresentado na figura 3.2. Foram detectados os blobs escuros porque o objetivo do processamento era avaliar a habilidade do método em identificar as estruturas cardíacas e as artérias, que nessa modalidade e tipo de aquisição aparecem como regiões mais escuras do que o fundo.

Na figura 4.15 são apresentados os blobs, obtidos em dez escalas, superpostos à imagem original e, na figura 4.16, as setas finas indicam blobs determinados como os mais proeminentes utilizando o método descrito neste capítulo. Nesta etapa do processamento, o resultado é apresentado como um *array* com o número identificador dos SSBlobbs mais relevantes, em ordem decrescente.

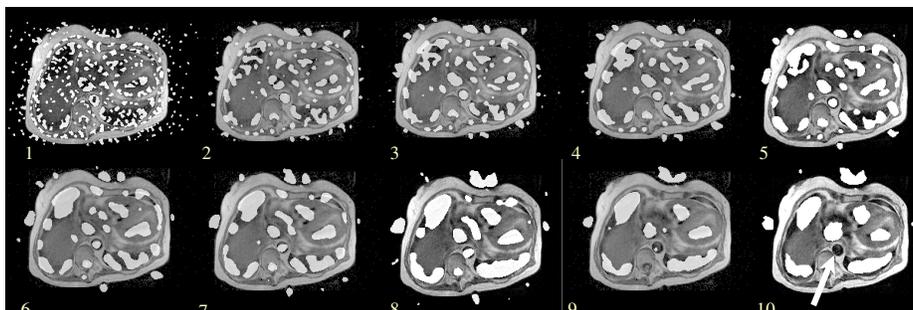


Figura 4.15. Superposição dos blobs, encontrados para os 10 níveis do espaço de escalas, à imagem original. Blobs extraídos em 10 níveis: $\sigma_1 = 1,19$; $\sigma_2 = 1,41$; $\sigma_3 = 1,68$; $\sigma_4 = 2,00$; $\sigma_5 = 2,37$; $\sigma_6 = 2,82$; $\sigma_7 = 3,35$; $\sigma_8 = 3,97$; $\sigma_9 = 4,72$; $\sigma_{10} = 5,61$. A seta no nível 10 indica a seção da aorta, que não foi identificada nesta escala como um GLBlob.

Analisando-se a figura 4.15, pode-se observar que nos níveis mais baixos existe a detecção de um número muito grande de pequenas estruturas, originadas principalmente pela presença de ruído. À medida em que o parâmetro de escala aumenta, os blobs originados de ruído começam a desaparecer e as estruturas relevantes da imagem começam a se revelar, embora de forma ainda desconexa. Em um determinado nível, elas começam a se manifestar como formas únicas. Uma estrutura desaparece quando o parâmetro de escala se torna maior do que a própria estrutura, como por exemplo a seção da aorta, indicada pela seta vermelha na escala 10 da figura. Observa-se, ainda, a formação de estruturas estáveis

no espaço de escalas que não estão relacionadas a nenhuma estrutura geométrica presente na imagem analisada, mas refletem apenas formações aleatórias causadas pela suavização de ruído. Esse fenômeno tende a ocorrer em regiões homogêneas da imagem.

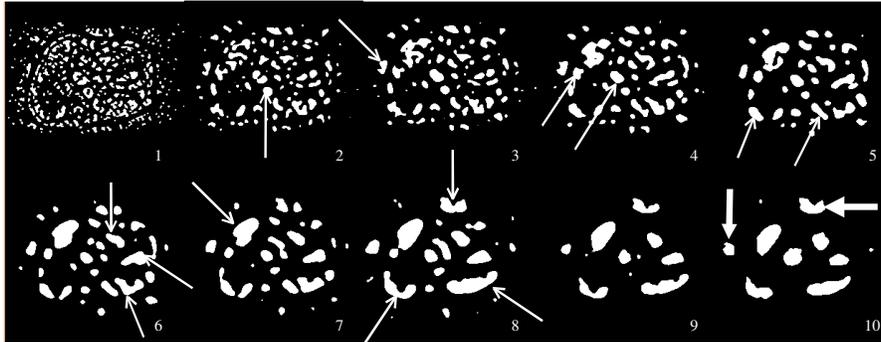


Figura 4.16. Imagens de blobs mostradas na figura 4.15. As setas finas indicam as regiões mais proeminentes, determinadas pelo método proposto. As duas regiões indicadas pelas setas grossas na escala 10 são formações originadas por ruído que sobrevivem até escalas mais altas.

As setas finas da figura 4.16 apresentam as treze regiões mais significativas encontradas a partir da utilização da metodologia proposta para a extração de estruturas importantes, sem qualquer conhecimento *a priori* sobre a imagem. Observa-se que, entre as estruturas mais proeminentes, encontram-se aquelas correspondentes às regiões anatômicas (partes do pulmão direito, pulmão esquerdo, cavidades cardíacas e vasos). Entretanto, estão também presentes estruturas sem significado anatômico, como partes desconexas de órgãos em escalas mais baixas e formações originadas por ruído (setas grossas)^{4.12}.

As suposições originais propostas por Lindeberg, sobre estabilidade de estruturas ao longo do espaço de escalas e caracterização de significância de estruturas pelo volume total nas escalas, são eficientes na etapa de reconhecimento de estruturas presentes na imagem e não para identificação de uma estrutura particular. Mesmo para a realização eficiente da tarefa de reconhecimento de estruturas reais, é necessária a inclusão de outras suposições ou informações, pois o resultado da classificação baseada no volume normalizado inclui agrupamentos aleatórios de pixels como estruturas significativas.

^{4.12} Os resultados foram publicados por Rebelo *et al.* (1998 e 2000).

4.5. Inclusão de informação *a priori* no SSPS

Conforme discutido no item 4.2.6, neste trabalho o SSPS é utilizado como estrutura de dados para a fase de processamento de alto nível, na qual o conhecimento sobre o domínio do problema é um requisito fundamental. No próximo capítulo, será apresentado o método proposto para identificação de estruturas, baseado na inclusão de informações *a priori* no SSPS. Será apresentada, ainda, uma aplicação piloto para testar a eficiência do método.

One day Alice came to a fork in the road and saw a Cheshire cat in a tree. Which road do I take? she asked. Where do you want to go? was his response. I don't know, Alice answered. Then, said the cat, it doesn't matter.

- Lewis Carroll

Capítulo 5

Inserção de informações *a priori* no SSPS

Neste capítulo, apresenta-se a proposta de utilização de SSPS como estrutura de dados para o casamento de padrões. Com esse objetivo, propõe-se a inclusão de informação *a priori* sobre o objeto procurado e sobre o contexto da imagem na qual ele está inserido. O tipo de informação depende da aplicação considerada. Com o objetivo de avaliar a robustez e a eficácia da representação, foi implementada uma aplicação piloto, na qual é definido um conjunto de características para identificação. No final do capítulo, apresenta-se um exemplo com o conjunto completo de representações utilizadas no método, desde a imagem original até a árvore de SSBlobs, com informação *a priori* já embutida.

5.1. Inclusão de informações *a priori* no formalismo de SSPS.

Os resultados apresentados no capítulo anterior indicaram que a utilização da representação de *Scale Space Primal Sketch* pode produzir resultados satisfatórios em aplicações de identificação de estruturas em imagens médicas. Remetendo à figura 2.5, a construção do SSPS caracteriza uma representação geométrica que pode ser utilizada como entrada para processos de identificação de uma determinada estrutura procurada. Conforme discutido no capítulo 2, a etapa de processamento de alto nível supõe o conhecimento de informação contextual do problema.

O que se propõe, então, é incluir informações *a priori* sobre os objetos procurados na estrutura do SSPS, resultando em uma representação geométrica potencialmente poderosa, capaz de embutir a informação de escala e que permita tratar de estruturas de tamanhos diferentes. A partir dessa representação geométrica, podem ser criados padrões que possibilitem a identificação em novas imagens. O esquema proposto para identificação, baseado nas etapas apresentadas no item 2.1, é apresentado na figura 5.1, a seguir:

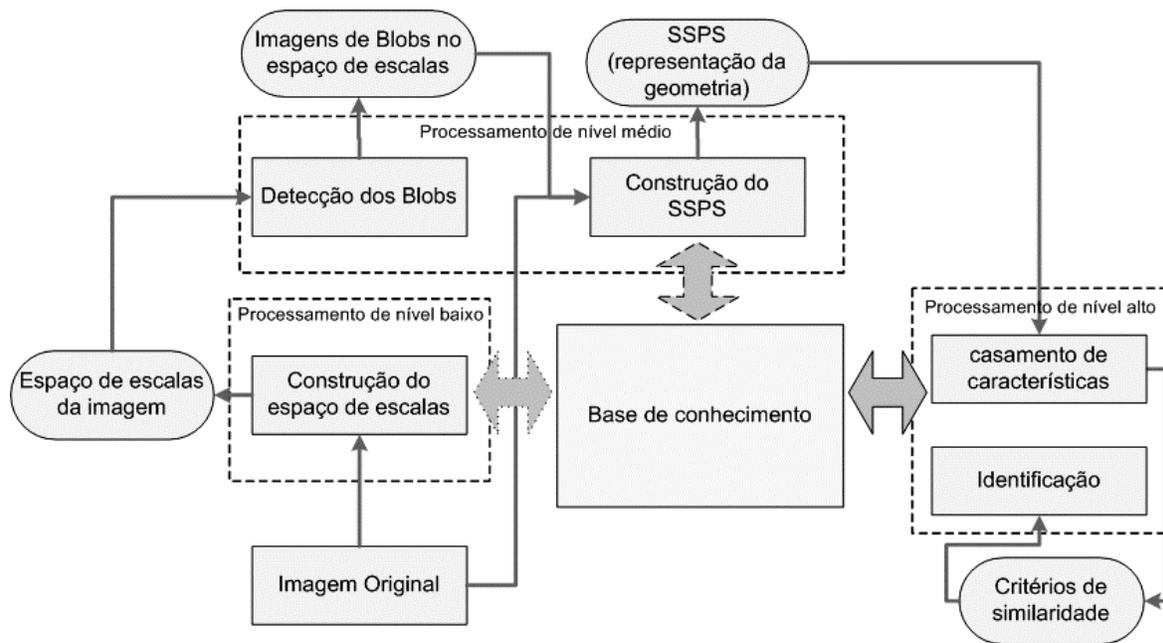


Figura 5.1. Esquema global das etapas e níveis de representação envolvidos no método proposto.

A identificação automática dos objetos de interesse em uma imagem envolve a descrição da mesma em termos de objetos presentes, suas relações e suas propriedades. Todas essas informações podem ser embutidas na estrutura SSPS. Surge, então, a questão da definição de que tipo de informação é relevante para a inclusão na representação. A resposta a esta questão é dependente do domínio do problema, e inclui aspectos como a modalidade médica analisada, o tipo de estrutura a ser identificada e a representação de estruturas biológicas em imagens médicas. A solução dessa última questão não é trivial e constitui uma parte importante da solução do problema.

A partir da representação construída, podem ser utilizadas diversas estratégias para a identificação. A escolha da estratégia também depende do nível de complexidade do problema em questão.

Por fim, existe ainda a questão de como tornar a representação SSPS eficiente para a busca de estruturas. A implementação descrita no capítulo 4 não é particularmente útil para essa tarefa. No item a seguir, a questão da representação será discutida detalhadamente.

5.1.1. Representação em árvore do SSPS

A representação das estruturas em múltiplas escalas e os tipos de eventos que podem ocorrer no SSPS são bem caracterizados por uma representação computacional de árvore. Além disso, essa representação é particularmente adequada para tarefas de busca e casamento de características (Gonzales, 2000). De forma resumida, a árvore para representação do SSPS é construída da seguinte forma:

- o nó inicial ou raiz da árvore contém o SSBlob que sobrevive na escala mais alta;
- a árvore é criada a partir da divisão do blob inicial: cada um de seus SSBlobs filhos constitui um novo nó;
- novos nós são criados a partir das divisões dos SSBlobs filhos.

A descrição da construção da árvore será apresentada detalhadamente a partir do exemplo a seguir, no qual se apresenta o ciclo completo de representações, desde a imagem original até a árvore de SSBlobs.

A figura 5.2 apresenta a imagem original, gerada a partir de manipulações^{5.1} de cortes do *phantom* MCAT (UNC, 2005), com resolução de 64 x 64 pixels. A imagem representa um corte da região abdominal, no qual estão presentes três órgãos. As figuras 5.3.a e c apresentam 14 níveis do espaço de escalas da imagem apresentada na figura 5.2, obtido a partir da convolução da imagem com filtros gaussianos com variância crescente, de

^{5.1} Foram feitas manipulações no *phantom* (soma de diferentes cortes, operações de espelhamento) com o objetivo de aumentar a complexidade da imagem e, conseqüentemente, da busca na árvore.

acordo com a expressão 3.7, com $\tau = 0,19$. Em 5.3.b e d, apresentam-se os GLBlobs, blobs de nível de cinza, de cada escala correspondente em a e c.

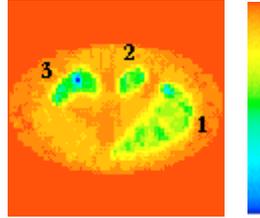


Figura 5.2. Imagem de teste bidimensional, gerada a partir do *phantom* MCAT com resolução de 64×64 pixels, na qual foram simuladas 3 estruturas com intensidade menor do que o fundo. Na tabela de cores utilizada, apresentada à direita da figura, os valores mais baixos de intensidade são representados pelo azul.

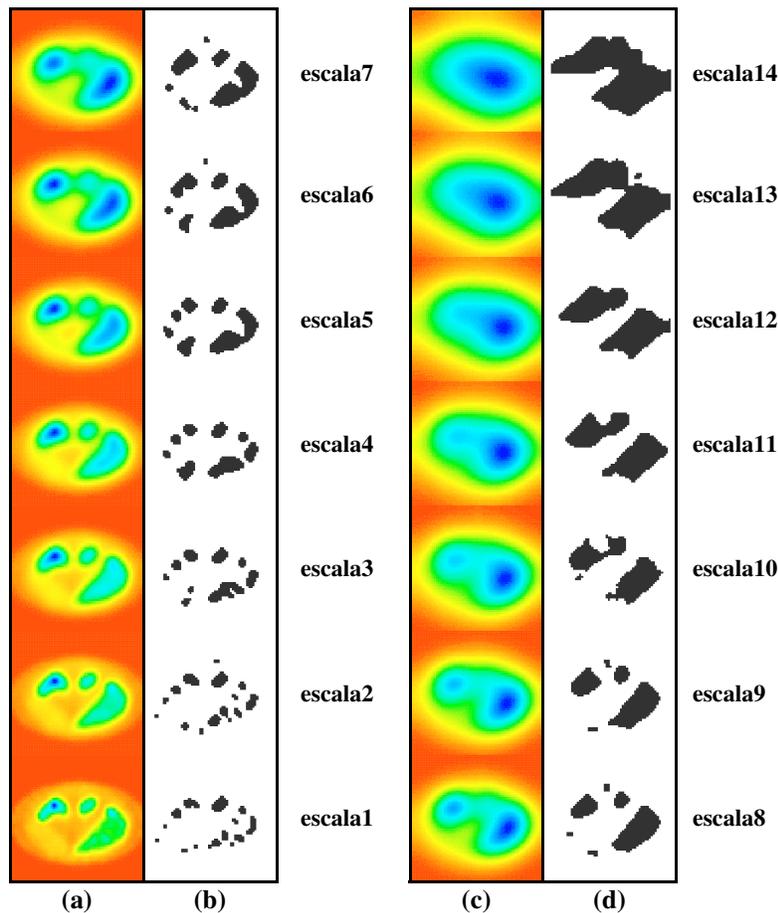


Figura 5.3.(a) e (c) Quatorze níveis do espaço de escalas da imagem apresentada na figura 5.2, $\tau = 0,19$. (b) e (d) Imagens com os GLBlobs, detectados pelos operadores descritos no capítulo 4, em cada nível do espaço de escalas.

As imagens do espaço de escala são imagens generalizadas, pois embora tenham sido obtidas a partir do processamento da imagem original, não ressaltam nenhuma característica que possa ser utilizada para identificação. As imagens de GLBlobs constituem imagens segmentadas, pois representam uma imagem de características da imagem original.

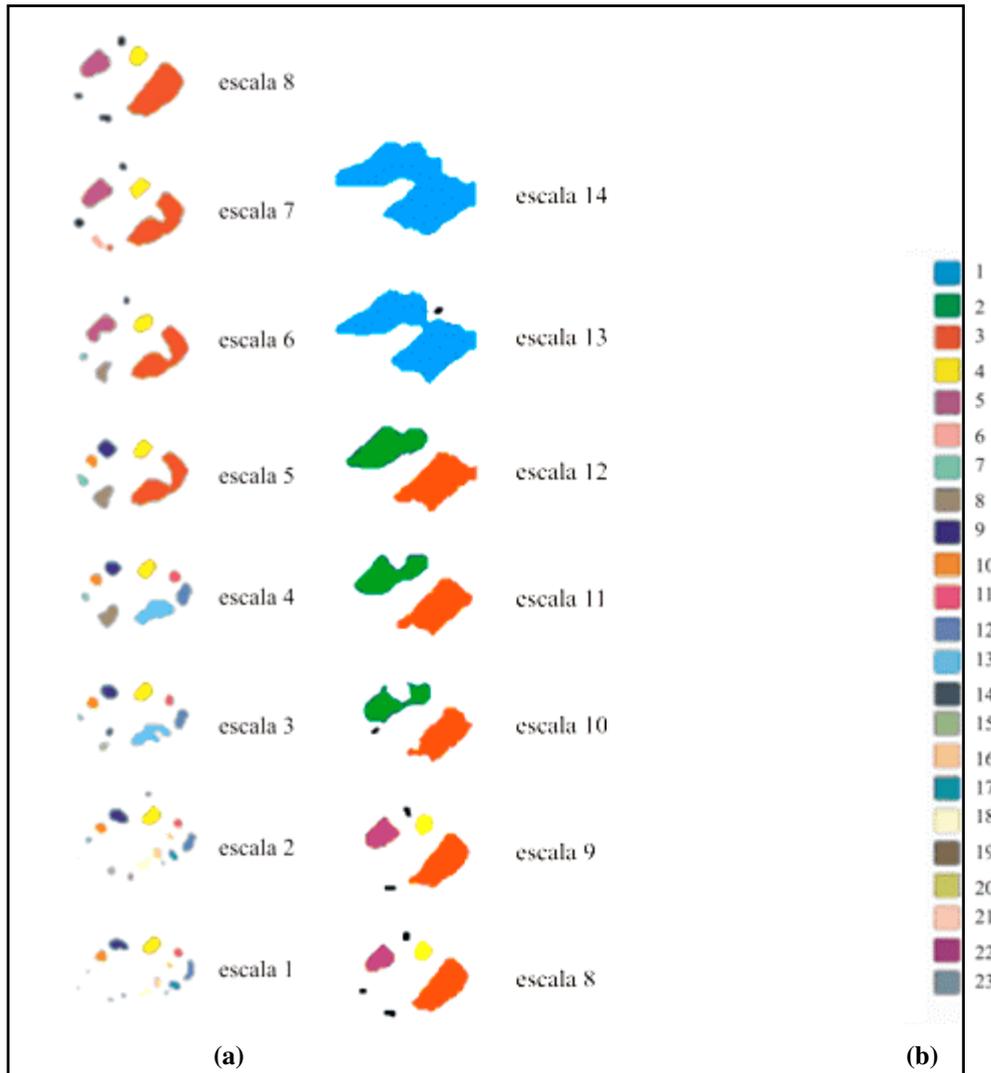


Figura 5.4. *Scale Space Primal Sketch* do espaço de escalas da imagem apresentada na figura 5.3. (a) GLBlobs em escalas diferentes com a mesma cor formam um SSBlob. Em (b) são apresentadas as codificações de cores para os 23 SSBlobs identificados.

Na figura 5.4.a apresenta-se o conjunto de SSBlobs do espaço de escalas da figura 5.3.a e c, obtidos através da rotina *primaltree*, citada no item 4.3.2. Os dados de cada SSBlob são representados pela estrutura de dados *Blob_scalespace*, apresentada no item

4.3.3. Na figura 5.4, os GLBlobs que formam um SSBlob são identificados por uma mesma cor. O propósito desta figura é fornecer um exemplo visual dos eventos de SSBlobs. Na figura 5.4.b, os 23 SSBlobs detectados são identificados através de uma tabela de cores.

A figura 5.4.a permite analisar o comportamento dos GLBlobs ao longo do espaço de escalas, de como e onde ocorreram os eventos de acoplamento, aparecimento e desaparecimento de SSBlobs. A informação apresentada desta forma é, entretanto, meramente visual. Embora as estruturas de dados que descrevem cada um dos SSBlobs contenham todas as informações necessárias para o seguimento das estruturas, é preciso estabelecer uma representação eficiente para o tratamento computacional das informações contidas na elaboração do SSPS.

A proposta é transformar o SSPS, apresentado na figura 5.4, em uma estrutura computacional de árvore. Essa transformação permite uma manipulação computacional mais eficiente, pois o percurso pelos nós reflete os eventos de formação, destruição e acoplamento de SSBlobs. Essa representação permite a utilização de várias abordagens para reconhecimento e identificação de estruturas.

A construção da árvore é iniciada na escala mais alta do espaço de escalas, e o SSBlob que é a união de todas as estruturas da imagem representa o nó-raiz. A partir desse nó inicial, a árvore é construída pela adição dos SSBlobs que se agruparam para formá-lo. Esses SSBlobs são os filhos do nó inicial. É criado um arco entre o nó-raiz e cada um dos filhos. Para cada um dos nós-filhos, o processo é repetido até que se atinja um SSBlob que não se formou pela aglutinação de dois ou mais SSBlobs, chegando a uma folha da árvore. Os arcos dessa árvore representam, desta forma, relações de agrupamento entre os nós do nível inferior que formam o nó no nível superior.

Na figura 5.5, são apresentados, a título de exemplo, três nós dessa representação. A figura 5.6 apresenta a representação em árvore dos SSBlobs identificados no conjunto de espaço de escalas da figura 5.4.

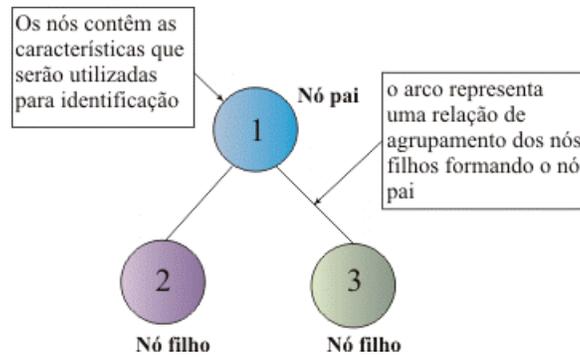


Figura 5.5. Exemplo de relação representada pela estrutura de árvore proposta

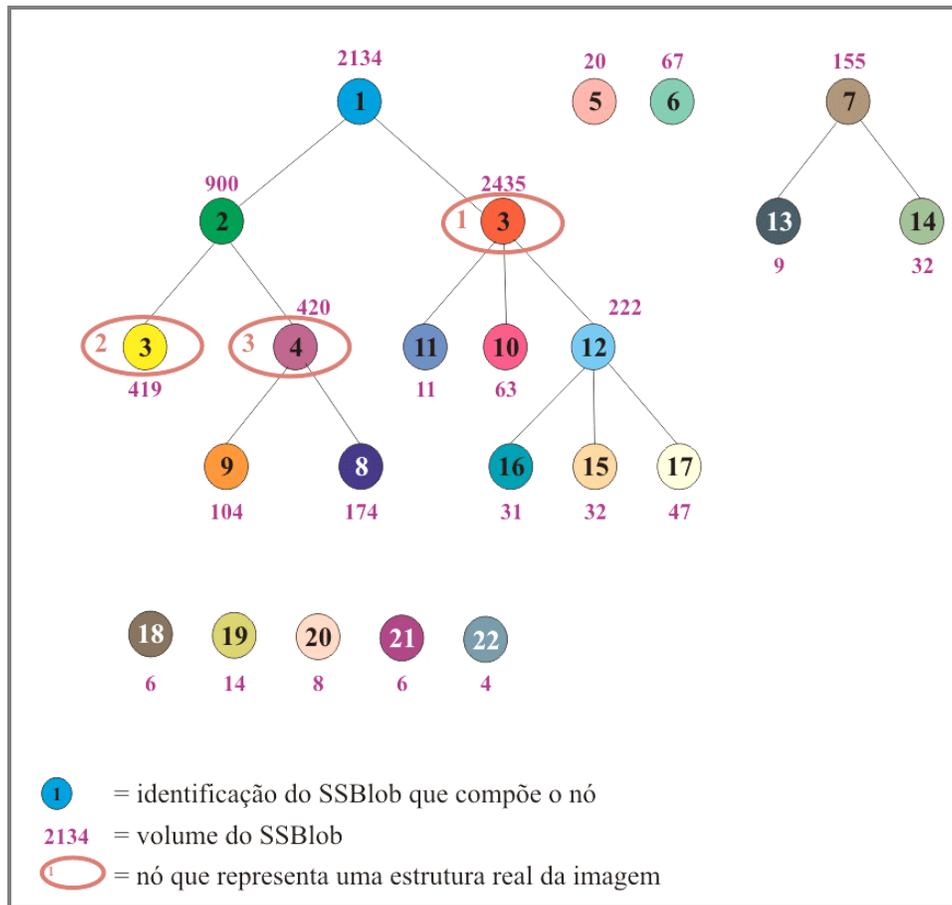


Figura 5.6. Representação em árvore do SSPS apresentado na figura 5.4.a. Foi mantida a tabela de cores dos SSBlobs da figura 5.4.b. Os números acima dos nós representam o parâmetro volume do SSBlob. Os três nós que representam as estruturas presentes na imagem original são destacados na figura.

Uma observação importante a ser feita neste ponto é que, para os experimentos realizados nos capítulos 5 e 6, o conceito de volume de SSBlob foi modificado em relação ao apresentado na estrutura de dados *Blob_scalespace*, apresentada no item 4.3.3. Nestes experimentos, pretende-se avaliar a utilização de informação geométrica, e por isso a componente de intensidade será retirada do volume do SSBlob, que passa a ser definido como a soma das regiões de suporte dos GLBlobs que compõem o SSBlob^{5.2}. Eventos de blobs envolvendo mais de três GLBlobs podem ocorrer, pois um nó pode ter mais do que 2 nós-filhos e, portanto, a árvore não é binária. A regra de ordenação vale para qualquer número de filhos. Os SSBlobs que aparecem em uma escala, sem que estejam relacionados a nenhuma estrutura na escala acima, iniciam uma nova árvore.

A característica que mais se destaca no conjunto de árvores visualizado na figura 5.6 é que os nós que descrevem as três estruturas presentes na imagem original se encontram no ramo principal, que é aquele cuja raiz começa na escala superior. Esse comportamento é facilmente explicável se for feita a suposição de que uma estrutura que exista realmente na imagem não deve simplesmente se desvanecer em alguma escala e sim, se agregar às outras estruturas presentes. Essa característica é apresentada na descrição do comportamento dos blobs feitas por Koenderink (1984) e Lindeberg (1993). Na descrição desse método, os autores afirmam que os blobs de nível de cinza são estruturas que se destacam do fundo e que essa característica se acentua nas escalas superiores. Portanto, um blob que descreve um órgão não deve desaparecer. Entretanto, fatores como ruído, contraste e erros de aproximação podem influenciar o comportamento dessas estruturas de forma imprevisível. Um dos comportamentos a ser estudado nos experimentos será o agrupamento, ou não, de órgãos presentes na imagem em um único SSBlob e a criação ou destruição, em escalas intermediárias do espaço de escalas, de SSBlobs que representem estruturas reais na imagem

^{5.2} A normalização em relação à escala é realizada de forma equivalente à apresentada no item 4.3.3.

5.2. Aplicação piloto

A representação proposta neste trabalho é bastante adequada para utilização na estratégia de modelos de ajuste a estruturas simbólicas, descrita no capítulo 2. Esta estratégia atua sobre um conjunto de características obtidas a partir dos dados da imagem. Na aplicação analisada neste texto, será efetuado um casamento entre os dados presentes na árvore de SSBlobs com um padrão armazenado em base de dados. A figura 5.7 apresenta o esquema para identificação utilizado na aplicação.

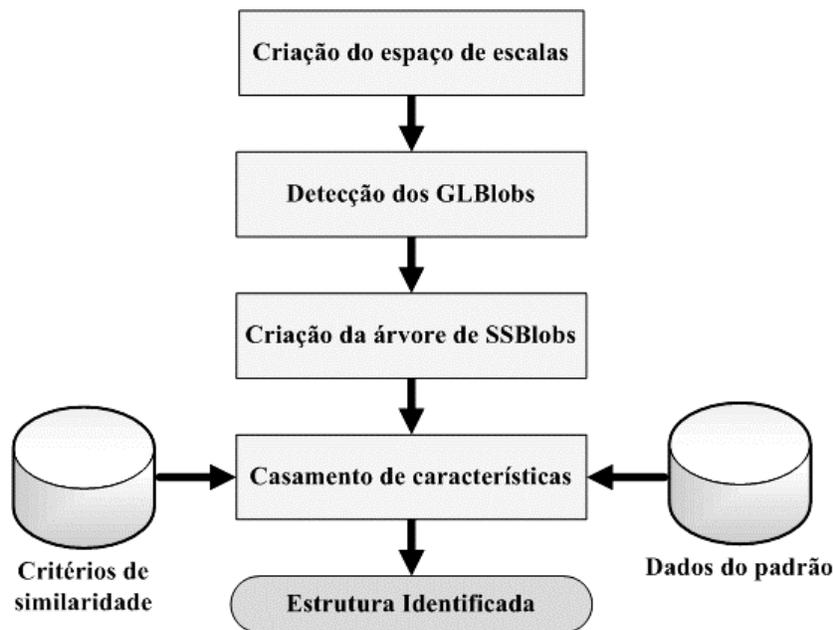


Figura 5.7. Esquema global do método proposto para a aplicação piloto.

Na aplicação piloto, foi escolhido um conjunto mínimo de características geométricas e de contexto na imagem para a representação de um órgão:

- o volume do SSBlob;
- a região de suporte do GLBlob;
- posição relativa entre a estrutura procurada e as demais presentes na imagem, especificada pelas distâncias entre a estrutura procurada e as demais e pelos ângulos formados pelos segmentos de reta que unem os centros geométricos da estrutura procurada e das demais estruturas.

A classificação final é dada em função da semelhança entre os valores de volumes, região de suporte, distâncias e ângulos de uma imagem teste em relação a um padrão armazenado.

Analisando a imagem 5.4, observa-se que, nas imagens dos níveis de escala mais baixos o número de GLBlobs presentes é muito grande. Assim, para esses níveis, o número de distâncias e, especialmente, o de ângulos a serem calculados e comparados crescem muito, de forma a tornar a busca pelo nó mais similar muito custosa computacionalmente. Optou-se por diminuir o número de combinações possíveis para o casamento de características. Essa redução foi realizada utilizando os seguintes critérios:

1. redução do número de nós elegíveis para a fase de casamento das estruturas geométricas, utilizando um parâmetro mais global para comparação com o padrão. O parâmetro utilizado foi o volume do SSBlob, conforme redefinido no item 5.1.1. O experimento apresentado no capítulo 4, com a imagem do tórax por ressonância magnética, mostrou a potencialidade de utilizar a informação desse parâmetro no reconhecimento de estruturas importantes na imagem. No protótipo, será utilizada apenas a informação geométrica, pela exclusão da informação de intensidade do volume de SSBlob. Pela aplicação deste critério, eliminam-se os nós que apresentarem um valor muito discrepante em relação ao padrão. Detalhes sobre as condições para eliminação serão descritos no item 5.2.1.
2. determinação de um nível de escala mais adequado para a operação de casamento de características geométricas e contextuais para os nós remanescentes. A definição do conceito de escala mais adequada e a forma de sua determinação serão apresentados no item 5.2.2.

5.2.1. Eliminação de nós na árvore de SSBlob utilizando volume total das estruturas

Conforme descrito no item anterior, a redução do número de nós é realizada utilizando como fator discriminante o parâmetro volume do SSBlob. Os passos realizados são os seguintes:

1. a partir do nó inicial, percorre-se toda a árvore e o volume de SSBlob de todos os nós são avaliados;
2. se o valor for muito maior do que o volume da estrutura procurada, obtido a partir do padrão, esse nó não é marcado como possível candidato. Entretanto, um de seus descendentes pode ser um candidato e deve ser avaliado;
3. se o volume for muito menor do que o da estrutura esperada, esse nó não é marcado como possível candidato e seus descendentes não são avaliados;
4. se o volume for próximo ao valor esperado, esse nó é marcado como possível candidato.

Para os nós marcados como candidatos é feita a análise de distâncias, ângulos e região de suporte. São calculados os ângulos e distâncias para todas as estruturas na escala mais adequada.

5.2.2. Determinação da escala mais adequada

A determinação da escala para o cálculo da similaridade geométrica e contextual, na qual são computados os ângulos e as distâncias, é feita pela aplicação e análise do método ao conjunto de imagens padrão.

No capítulo 3 deste trabalho foi discutido o conceito de escala apropriada para processamento de imagens. O conceito se baseia na idéia de que o grau de suavização no qual um objeto desaparece revela o tamanho desse objeto. Nesse capítulo, foram apresentados alguns trabalhos que visavam determinar as escalas apropriadas, para o caso em que a análise da imagem era realizada sem nenhum conhecimento *a priori* sobre as estruturas presentes.

No presente trabalho, pressupôs-se o conhecimento *a priori* de quais estruturas compõem a imagem em estudo. Procurou-se equacionar a determinação das escalas de aparecimento e desaparecimento de uma estrutura de tamanho conhecido. Procurava-se encontrar a relação entre o tamanho da estrutura desejada e os valores de σ , nos quais a estrutura poderia ser detectada como uma estrutura única na imagem, a partir da aplicação

de um determinado operador. Um dos objetivos do desenvolvimento dessa abordagem era contribuir para área de pesquisa de métodos analíticos na determinação de escala apropriada. O desenvolvimento dessa abordagem foi feito para o caso de uma única estrutura utilizando dois operadores: o operador limiar e o operador *umbilicity*. A análise utilizando o operador limiar foi feita para um sinal unidimensional, supondo uma onda quadrada com amplitude a e extensão b , submetida à convolução com gaussianas com variâncias progressivamente maiores, e supondo a função limiar como $1/3 a$. O desenvolvimento da teoria indica que a estrutura é detectada em pelo menos um ponto – o ponto central – para valores de σ até $1,16b$. Os pontos de borda da onda quadrada são detectados para valores de σ até b .

A análise de manifestação das estruturas ao longo das escalas deve também considerar a existência de outras estruturas próximas à de interesse. Devido ao borramento, a presença de outras estruturas próximas modifica o comportamento previsto teoricamente, pois as estruturas se acoplam para formar uma nova estrutura em escalas nas quais a estrutura de interesse se manifestaria, caso estivesse isolada. A inclusão da influência de uma outra estrutura na imagem foi feita para o caso do operador limiar. A teoria foi desenvolvida para um sinal unidimensional com duas ondas quadradas de mesma extensão b e amplitude a , que estão localizadas a uma distância b . Utilizando a mesma função limiar do caso de uma única estrutura, $1/3 a$, obteve-se o seguinte resultado: é possível detectar as duas estruturas como entidades distintas para valores de σ até $0,52b$. A partir daí, as duas estruturas se acoplam para formar uma terceira, que será detectada até $\sigma = 2,13b$. A partir desse valor, nenhuma estrutura é detectada no sinal. No apêndice II apresenta-se o desenvolvimento completo e exemplos simulados das abordagens para verificação das escalas de sobrevivência, utilizando os dois operadores.

Uma deficiência presente na abordagem teórica desenvolvida é que ela não leva em consideração o nível de ruído presente na imagem, que faz com que estruturas maiores apareçam como múltiplas estruturas nas escalas mais baixas. Uma outra questão não abordada teoricamente é que o método para identificação de estruturas proposto neste trabalho não leva em consideração apenas a estrutura procurada, mas também as relações

desta estrutura com os outros elementos da cena. Assim, é razoável considerar que a escala escolhida para identificação da estrutura desejada deva incluir informação de escala não apenas da própria estrutura, mas também de suas vizinhas. Uma abordagem mais abrangente e apropriada consiste em determinar as faixas de escalas de sobrevivência para cada uma das estruturas. Para este trabalho, essa é a faixa de escalas que pode ser definida como faixa de escalas apropriadas, pois nelas estão presentes todos os elementos do contexto da imagem e permitem uma melhor avaliação de similaridade. Como os resultados obtidos na abordagem teórica não permitem a determinação dessa faixa de escalas, eles não foram utilizados na implementação do protótipo.

A faixa de escalas desejada pode ser obtida experimentalmente, pela aplicação do método proposto ao conjunto de imagens utilizadas para determinar o padrão. Um exemplo dos conceitos expostos é apresentado na figura 5.8., na qual se apresenta uma imagem de 64 x 64 pixels com quatro estruturas. Na Tabela 5.1, são apresentadas as dimensões das estruturas presentes na imagem e na Tabela 5.2, os valores de σ das escalas do espaço de escalas construído para essa figura e as faixas de escalas de sobrevivência de cada uma das estruturas. A faixa de escalas nas quais todas as estruturas estão presentes começa na escala 9 e vai até a escala 6 (região sombreada da tabela). A determinação de distâncias e ângulos em qualquer uma dessas escalas garantiria que o método trabalhe com o máximo de informação contextual possível.

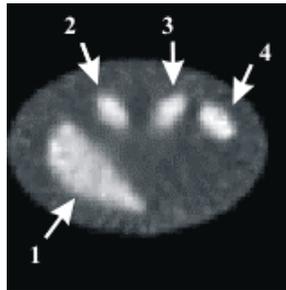


Figura 5.8. Exemplo de uma imagem 64 x 64 pixels. As quatro estruturas presentes são identificadas pelos números sobrepostos. Na tabela 5.1 são apresentadas as dimensões das quatro estruturas e na tabela 5.2, as faixas de sobrevivência de cada uma delas.

Tabela 5.1. Dimensões e contagem média das quatro estruturas, tórax e fundo da imagem apresentada na figura 5.8.

estrutura	eixo maior (pixels)	eixo menor (pixels)	contagem média
1	19	8	175
2	6	3	214
3	6	3	214
4	7	4	244
tórax	58	38	22
fundo	64	64	0

Tabela 5.2. Faixa de sobrevivência no espaço de escalas das quatro estruturas da imagem apresentada na figura 5.8. Na segunda coluna da tabela são indicados os valores de σ de cada nível do espaço de escalas, em pixels. Na terceira coluna são indicadas as faixas de sobrevivência de cada estrutura. Os níveis de escala demarcados pelas duas linhas são aqueles nas quais há sobreposição da presença de todas as estruturas reais da imagem.

escala	σ (pixel)	faixa de sobrevivência
1	1,13	
2	1,27	
3	1,43	
4	1,61	
5	1,82	
6	2,05	
7	2,32	
8	2,61	
9	2,94	
10	3,32	
11	3,74	
12	4,22	
13	4,76	
14	5,37	
15	6,05	

Considera-se que na escala mais alta dentre as escalas apropriadas da imagem o processamento pode ser otimizado. Essa escala será chamada aqui de escala adequada para processamento. As razões para escolha dessa escala são as seguintes:

- nas escalas mais baixas, a probabilidade de existência de estruturas espúrias é maior, o que aumenta o número de possibilidades de cálculos inúteis de distâncias e ângulos. Um número maior de estruturas espúrias na imagem poderia aumentar, também, o índice de erro no casamento de estruturas;
- embora nas escalas mais altas as estruturas estejam mais borradas, os cálculos de distância e ângulos são pouco afetados pois são feitos em relação aos centros geométricos de cada estrutura. Estes pontos não devem modificar sua posição pois a operação aplicada entre as escalas é a convolução com a gaussiana, que apenas provoca um borramento, mas mantém a posição relativa entre as estruturas.

Um problema que pode ocorrer com a utilização dessa abordagem é a probabilidade de inexistência de uma escala na qual todas as estruturas reais da imagem estejam representadas por blobs únicos. Isso pode acontecer, por exemplo, quando uma estrutura pequena e com contraste baixo estiver presente na imagem. Ela deve aparecer apenas em níveis muito baixos, quando estruturas maiores, em geral, já não constituem um único elemento na imagem, devido ao ruído. Neste caso será considerada a escala mais alta na qual a estrutura de interesse aparece e serão desconsideradas as estruturas que não são representadas por um único blob nessa escala.

Cabe ressaltar que, embora os resultados do equacionamento teórico não tenham sido utilizados na implantação do método proposto para a identificação de estruturas, os resultados obtidos e sua validação experimental sugerem que essa é uma linha de pesquisa promissora e que deve ser estendida em trabalhos futuros, de modo a incluir na sua formulação as variáveis ausentes da abordagem realizada neste trabalho.

5.2.3. Esquema final da aplicação piloto

Na figura 5.9, apresenta-se o esquema global do método para identificação automática de estruturas proposto na aplicação piloto.

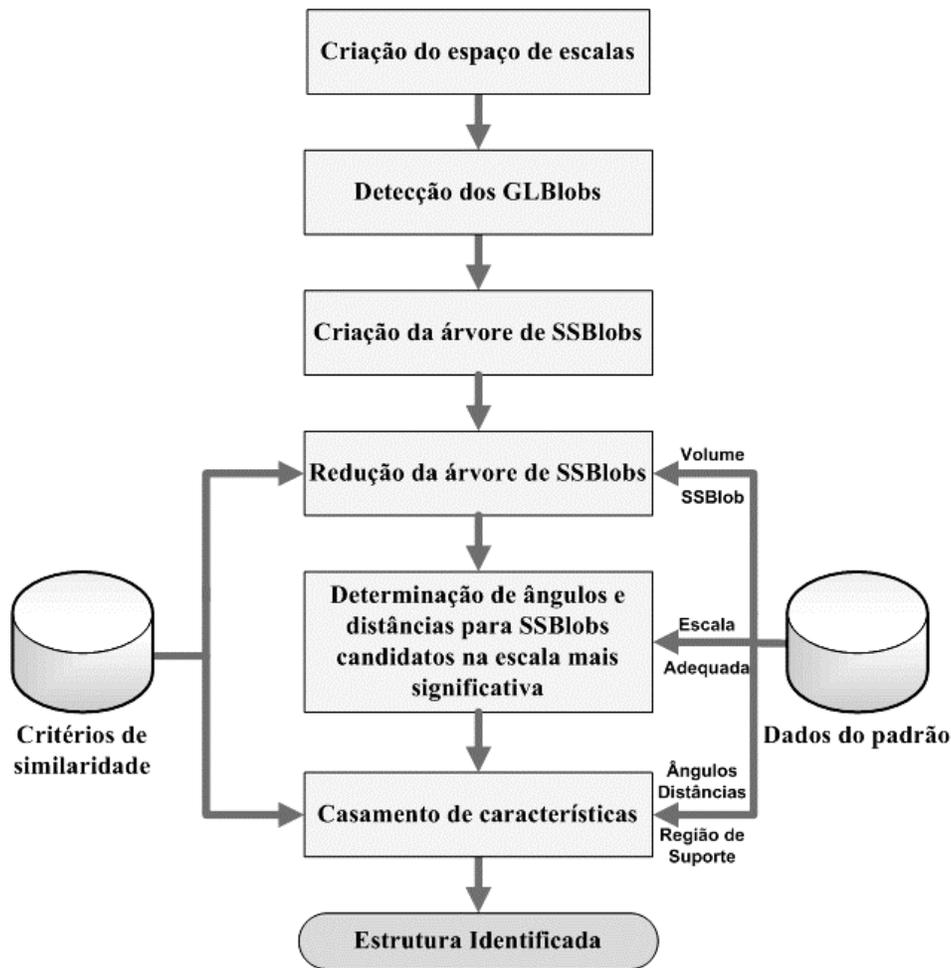


Figura 5.9. Esquema global do método proposto para a aplicação piloto, incluindo a redução da árvore e escolha da escala adequada.

O método consiste das seguintes fases:

1. convolução da imagem inicial com filtros gaussianos, para criação do espaço de escalas;
2. aplicação do operador *umbilicity* em cada nível do espaço de escalas, para detecção dos GLBlobs;
3. determinação das relações entre os GLBlobs para criação do SSPS;

4. casamento do volume total de cada SSBlob da árvore com o valor padrão para redução do número de nós da árvore. Os nós remanescentes são chamados de *nós candidatos*;
5. cálculo dos ângulos e distâncias na escala adequada para os nós candidatos;
6. casamento dos parâmetros calculados para cada SSBlob com os valores do padrão;
7. a identificação da estrutura é realizada a partir do cálculo de similaridade entre o padrão e os nós candidatos. Considera-se que a estrutura desejada é aquela representada pelo nó com maior similaridade com o padrão.

5.2.4. Dados do padrão

O padrão é obtido a partir de um conjunto de dados reais, pela aplicação do método proposto. Os seguintes dados são armazenados no padrão:

- Resolução original da imagem;
- Valor de τ para criação do espaço de escalas;
- Volume do SSBlob que representa a estrutura;
- Escala mais adequada para processamento;
- Região de suporte do GLBlob na escala adequada;
- Número de distâncias na escala mais adequada;
- Número de ângulos na escala mais adequada;
- Conjunto com os elementos de distância obtidos na escala mais adequada;
- Conjunto com os elementos de ângulo obtidos na escala mais adequada.

5.2.5. Critério para redução da árvore de SSBlobs

São considerados nós candidatos aqueles cujo volume de SSBlob estiver contido em uma faixa de valores, definida em relação ao volume do padrão. Determinou-se, inicialmente, essa faixa como $\pm 20\%$. Um dos objetivos dos experimentos é avaliar se essa faixa é adequada.

5.2.6. Classificação de estruturas

O critério de similaridade utilizado na segunda etapa de casamento de características é dado pela distância euclidiana mínima entre os valores obtidos para a imagem teste e os valores definidos no padrão, para o conjunto de características escolhido. A formulação é dada a seguir.

Seja o elemento Φ de uma imagem a estrutura desejada, em uma dada escala n (definida pelo parâmetro σ_n), na qual existem outras três estruturas presentes. Esta estrutura pode ser caracterizada geometricamente pelo volume de SSBlob, pela região de suporte e pelas distâncias e ângulos em relação às outras três estruturas. As distâncias e ângulos são definidos em relação aos centros geométricos de cada uma das estruturas, conforme apresentado na figura 5.10.

O casamento de estruturas é feito levando-se em consideração os valores do vetor de características do padrão com os valores do vetor de características dos nós de uma nova imagem.

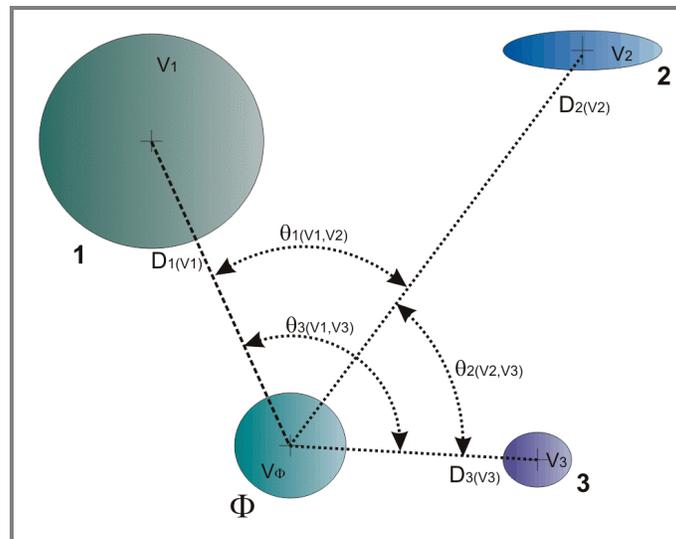


Figura 5.10. Exemplo de imagem com 4 estruturas. A estrutura procurada é Φ , que, na escala n , é caracterizada por um volume V_Φ . As estruturas 1, 2 e 3 são caracterizadas por seus volumes V_1 , V_2 e V_3 . Os parâmetros $D_{1(V1)}$, $D_{2(V2)}$, $D_{3(V3)}$ denotam as distâncias entre a estrutura Φ e as estruturas 1, 2 e 3, respectivamente. Os parâmetros $\theta_{1(V1,V2)}$, $\theta_{2(V2,V3)}$, $\theta_{3(V1,V3)}$ são os ângulos formados, respectivamente, por (1, Φ , 2), (Φ , 3) e (1, Φ , 3).

Seja o vetor de parâmetros definidos em um padrão, para a estrutura Φ , dado por:

$$\Phi \equiv \begin{bmatrix} V \pm \Delta V \\ D_{1(V1)} \pm \Delta D_1 \\ D_{2(V2)} \pm \Delta D_2 \\ D_{3(V3)} \pm \Delta D_3 \\ \theta_{1(V1,V2)} \pm \Delta \theta_1 \\ \theta_{2(V2,V3)} \pm \Delta \theta_2 \\ \theta_{3(V1,V3)} \pm \Delta \theta_3 \end{bmatrix} \quad (5.1)$$

ou alternativamente, omitindo-se os desvios:

$$\Phi = [V, D_{1(V1)}, D_{2(V2)}, D_{3(V3)}, \theta_{1(V1,V2)}, \theta_{2(V2,V3)}, \theta_{3(V1,V3)}] \quad (5.2)$$

Em uma nova imagem I , o vetor de parâmetros é dado por :

$$I \equiv \begin{bmatrix} VI \\ DI_{1(VI1)} \\ DI_{2(VI2)} \\ DI_{3(VI3)} \\ \theta_{1(VI1,VI2)} \\ \theta_{2(VI2,VI3)} \\ \theta_{3(VI1,VI3)} \end{bmatrix} \quad (5.3)$$

Para determinar a similaridade entre o padrão procurado e a nova imagem, é utilizado o parâmetro de distância entre os dois vetores, definido como:

$$Dist(\Phi, I) = \begin{bmatrix} |V - VI| \\ |D_{1(V1)} - DI_{1(VI1)}| \\ |D_{2(V2)} - DI_{2(VI2)}| \\ |D_{3(V3)} - DI_{3(VI3)}| \\ |\theta_{1(V1,V2)} - \theta_{1(VI1,VI2)}| \\ |\theta_{2(V2,V3)} - \theta_{2(VI2,VI3)}| \\ |\theta_{3(V1,V3)} - \theta_{3(VI1,VI3)}| \end{bmatrix} \quad (5.4)$$

O nó com o menor valor para $Dist(\Phi, l)$ é considerado como aquele que melhor representa a estrutura procurada.

Dependendo da faixa de valores de cada parâmetro, podem ser obtidos resultados incorretos, se utilizados os valores absolutos. Assim, é necessário realizar a normalização dos valores. Utiliza-se neste trabalho a estratégia proposta por Smith (2003) para a normalização. A obtenção dos valores de cada parâmetro é feita a partir de valores reais e a normalização pode ser feita utilizando a expressão (Smith, 2003):

$$V = \frac{V_{medido} - V_{min}}{V_{max} - V_{min}} \quad (5.5)$$

V_{medido} é o valor de uma medida particular; V_{min} é o menor valor do conjunto de medidas realizadas; V_{max} é o maior valor do conjunto de medidas realizadas. O valor normalizado de cada parâmetro é substituído na expressão 5.4.

5.3. Implementação

5.3.1. Ferramentas utilizadas e módulos implementados

As rotinas para criação da árvore de SSBlobs, geração do padrão e casamento de estruturas foram implementadas em linguagem Java, utilizando a ferramenta JBuilder 9.0.125.0 da Borland®. Optou-se por utilizar a linguagem Java nesta etapa do trabalho porque esta linguagem possui uma grande variedade de APIs (*Application Program Interface*) para desenvolvimento, uma interface gráfica rica, é fácil de programar e já possui uma representação gráfica implementada para estruturas de árvore. Além disso, esta etapa não requer cálculos matemáticos complexos como nas anteriores, para os quais a linguagem C é mais adequada, e a questão da visualização da representação em árvores é um fator determinante. Assim, considerou-se que a utilização da linguagem Java seria mais apropriada, pois ela permitiria um desenvolvimento mais rápido e uma visualização fácil dos resultados. Mais ainda, como uma característica desejada deste trabalho era que o software fosse independente de plataforma, a escolha natural foi pela linguagem Java. O desenvolvimento do software foi feito em microcomputador com sistema operacional

Windows XP™ e os testes foram realizados tanto nessa plataforma quanto em um servidor Intel® Xeon™, com sistema operacional Linux.

Foram desenvolvidos dois módulos nesta etapa:

- *CriaPattern*: geração do padrão a partir aplicação do método proposto a um conjunto de imagens; neste módulo existe interação do usuário para determinar os parâmetros que descrevem a estrutura desejada;
- *Blobscale_Comparação*: identificação da estrutura procurada em uma imagem teste, a partir do casamento com o padrão;

O software desenvolvido utiliza os seguintes arquivos, gerados em etapas anteriores do processo:

- *scaleblob.txt*: arquivo que contém a estrutura de dados SSPS;
- *queuescale.txt*: arquivo que contém os GLBlobs em cada escala, armazenados como uma estrutura de filas, que foi descrita no capítulo 4;
- *pattern.txt*: arquivo contendo as informações do padrão.

No apêndice III é apresentado o diagrama que mostra a interação entre os módulos desenvolvidos nas etapas anteriores e o software para geração da estrutura de árvores e casamento de estruturas.

5.4. Resultados

A seguir, apresentam-se os resultados da construção da árvore de SSBlobs para cinco imagens sem ruído do *phantom* MCAT, que contêm estruturas de tamanhos e contraste diferentes. As imagens são apresentadas na figura 5.11.

As cinco imagens foram obtidas a partir de manipulações de cortes do *phantom* MCAT e têm dimensão espacial de 64x64 pixels. As imagens do conjunto [1,2,3] são geometricamente idênticas, com diferenças apenas nos valores de contagens. O mesmo acontece para o conjunto [4,5]. A tabela 5.3 apresenta as dimensões e contagens das estruturas presentes nas imagens 1, 2 e 3. Os valores para as imagens 4 e 5 são apresentados na tabela 5.4

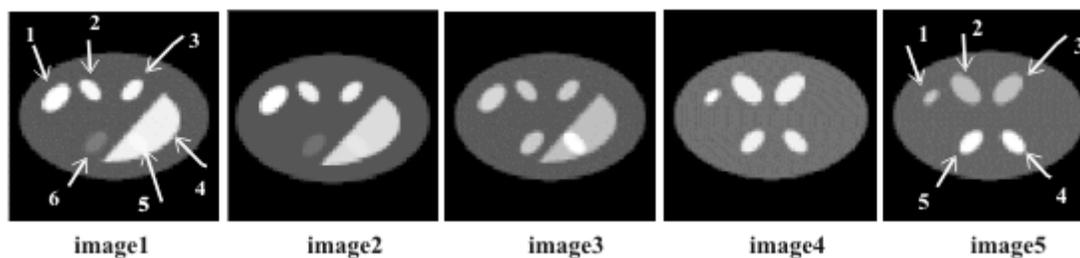


Figura 5.11. Imagens teste para visualização da árvore de SSBlobs, obtidas pela manipulação do *phantom* MCAT. Resolução das imagens 64x64 pixels.

Tabela 5.3. Dimensões e contagem média das estruturas das imagens image1, image2 e image3, mostradas na figura 5.11.

estrutura	eixo maior (pixels)	eixo menor (pixels)	contagem média image1	contagem média image2	contagem média image3
1	7	4	3228	3228	2208
2	5	3	3081	2833	1959
3	5	3	3081	2833	1959
4	20	8	2756	2320	1635
5	5	3	3037	2557	3228
6	6	3	642	541	1959
tórax	58	38	359	541	365
fundo	64	64	0	0	0

Tabela 5.4. Dimensões e contagem média das estruturas das imagens image4 e image5, mostradas na figura 5.11.

estrutura	eixo maior (pixels)	eixo menor (pixels)	contagem média image4	contagem média image5
1	3	3	3228	1816
2	7	4	2864	1648
3	7	4	2864	1648
4	6	3	2864	3228
5	6	3	2864	3228
tórax	58	38	534	454
fundo	64	64	0	0

Neste experimento inicial, pretende-se apenas exemplificar a visualização da estrutura de árvores de SSPS. As imagens utilizadas não são corrompidas por ruído e todas tem a mesma resolução espacial, 64 x 64 pixels. Pretende-se, aqui, fazer uma análise qualitativa de alguns fatores, como contraste e tamanho da estrutura, na forma da árvore final. No capítulo 6 será feita uma análise de cada uma das imagens, com adição de ruído gaussiano, em diferentes níveis, e também uma análise mais acurada da influência do contraste entre as estruturas na identificação.

Este experimento, assim como aqueles que serão apresentados no capítulo 6, foram realizados em dois ambientes:

- módulos *gauss*, *createblobs* e *primaltree*: servidor Sun Ultra Enterprise 450, Ultra4, 2GB de RAM.
- módulo *blobscale_Comparação*: microcomputador Pentium IV, Processador de 2.4 GHz, 512 MB RAM.

Para comparar o desempenho dos software desenvolvidos em plataformas distintas, todos os módulos também foram testados em um servidor Intel(R) Xeon(TM) 2 X CPU 2.80GHz HyperThreading, 2GB de RAM

Os espaços de escala das cinco imagens foram construídos utilizando o valor $\tau = 0,19$. Os GLBlobs de cada nível foram detectados e, a partir deles, foram determinados os SSPS para cada imagem. Os tempos de processamento para determinação dos SSPS – módulo *primaltree* - das cinco imagens variaram entre 2 e 5 segundos. Os conjuntos de GLBlobs das cinco imagens são apresentados na figura 5.12.

O valor de $\tau = 0,19$ será utilizado em todos os experimentos com imagens de resolução 64 x 64. Ele foi determinado empiricamente, a partir da análise qualitativa da detecção, para distintos valores de τ , de SSBlobs de estruturas com dimensões semelhantes àquelas que serão analisadas neste capítulo e no próximo. No apêndice IV apresenta-se uma análise qualitativa da influência do valor de τ .

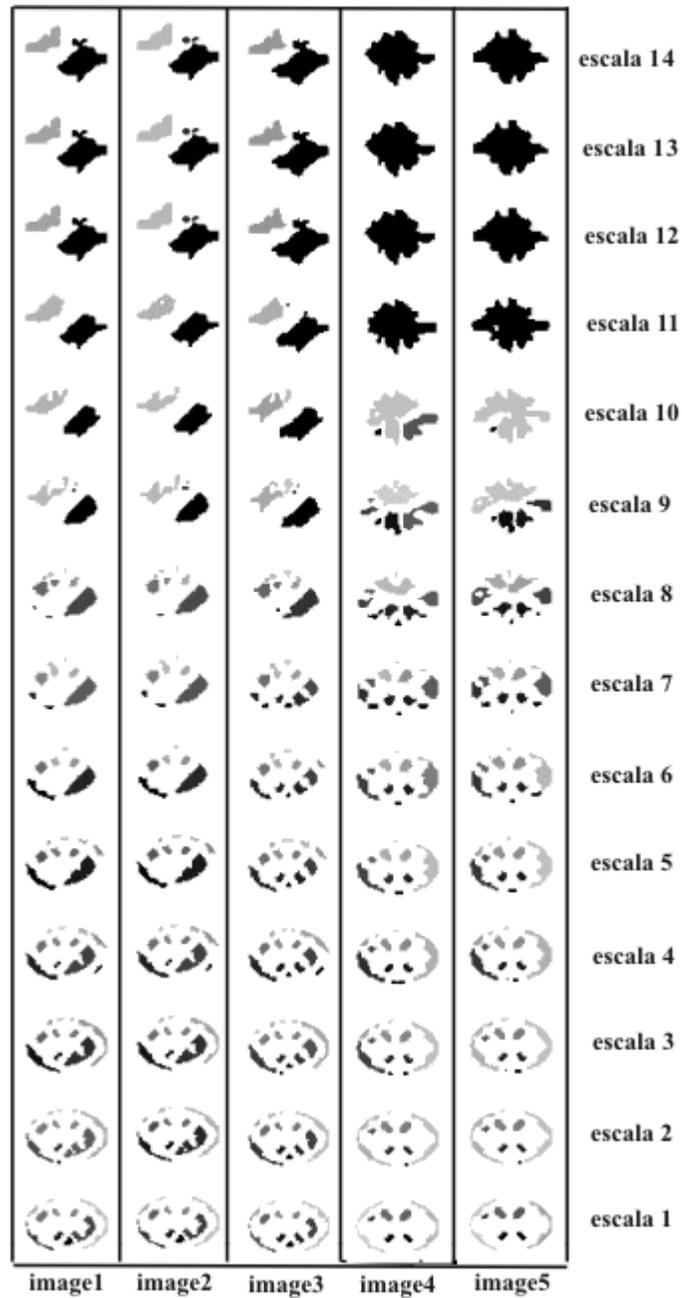


Figura 5.12. Blobs detectados nos espaços de escala das imagens apresentadas na figura 5.11, com $\tau = 0,19$.

No conjunto de imagens [1,2,3], a estrutura 4 – que representa o fígado – sobrevive sempre até o nível mais alto, reflexo do seu tamanho. O comportamento nos níveis inferiores depende do nível de contraste do defeito inserido no interior da estrutura. Na imagem 3, que apresenta o maior contraste entre o órgão e o defeito, o fígado só se

manifesta como uma única estrutura no nível 8 do espaço de escalas. É interessante notar que o defeito – estrutura 5 – não se manifesta como um blob em nenhuma das três situações de contraste. O seu efeito é notado pelo comportamento dos blobs que representam o fígado. As estruturas 1,2,3 e 6, embora de tamanhos semelhantes apresentam comportamentos bem distintos na árvore. A estruturas 1 e 2, que estão localizadas muito próximas, sempre se acoplam para formar uma nova estrutura, independentemente do contraste entre estas estruturas e o tórax. Os blobs representando as estruturas 3 e 6, que são mais isoladas, são destruídos em níveis de escala intermediários, antes que se acoplem a algum outro SSBlob. A escala de desaparecimento reflete o contraste da estrutura, conforme pode ser visto no comportamento da estrutura 6. Nas duas primeiras imagens, com contraste semelhante e muito baixo, ela sobrevive até a escala 4. Na imagem 3, com o nível de contraste aumentado, ela sobrevive até a escala 7.

No conjunto de imagens [4,5] as estruturas apresentam tamanhos semelhantes, à exceção da pequena estrutura 1. Nos dois casos, o comportamento dos SSBlobs é bastante semelhante: as quatro estruturas maiores se acoplam, primeiramente duas a duas com aquelas que estão mais próximas e depois ocorre o acoplamento das duas estruturas resultantes da primeira etapa; o SSBlob que representa a estrutura menor desaparece em níveis intermediários do espaço de escalas. Também neste caso, a escala de desaparecimento reflete o contraste entre a estrutura e o fundo. Na imagem 4 o SSBlob desaparece na escala 9, enquanto que na imagem 5, que apresenta contraste bem menor que no caso anterior, ele desaparece na escala 6.

Essas características observadas pela análise visual devem estar refletidas nas árvores de SSBlobs. As figuras 5.13 e 5.14 mostram as árvores de SSBlobs conjuntos de imagens [1,2,3] e [4,5], respectivamente.

Nas duas figuras, os nós que identificam cada estrutura real da imagem são identificados por um círculo ao redor do número do nó e pelo número da estrutura colocado entre parênteses à direita do nó. A numeração utilizada para identificar as estruturas de cada imagem é a apresentada na figura 5.11.

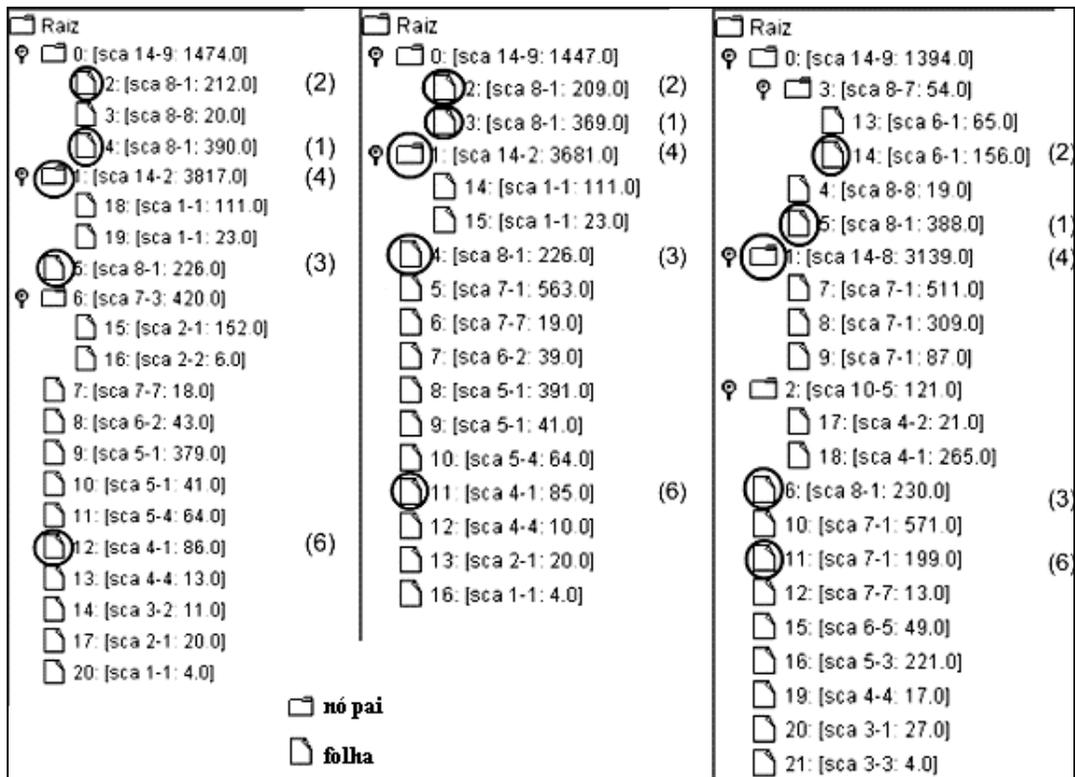


Figura 5.13. Árvores de SSPS obtida para as imagens image1 (esquerda), image2 (central) e image3 (direita) da figura 5.11. O nó Raiz é um artifício computacional para representar todos os nós como pertencentes à mesma árvore. O número inicial identifica o número do nó e as informações entre colchetes são as escalas de aparecimento e desaparecimento e o volume do SSBlob. Os nós marcados com um círculo são aqueles que representam as estruturas reais da imagem. O número entre parênteses, à direita desses nós, indica qual estrutura é representada por ele, segundo numeração das estruturas apresentada na figura 5.11.

O nó *Raiz* representa o nó-pai de todos os nós da árvore, porém não tem nenhum significado real na imagem ou na formulação dos SSBlobs. A estrutura de árvores implementada em Java impõe a existência de um nó-raiz, o que implica que todos os nós devem convergir para um único nó. Entretanto, a árvore da imagem apresenta nós que não possuem um nó-pai. Eles podem representar SSBlobs que desaparecem em escalas intermediárias, ou então, podem indicar que mais de um SSBlob sobrevive até a última escala. Desta forma, o nó *Raiz* é criado em todas as árvores de imagem.

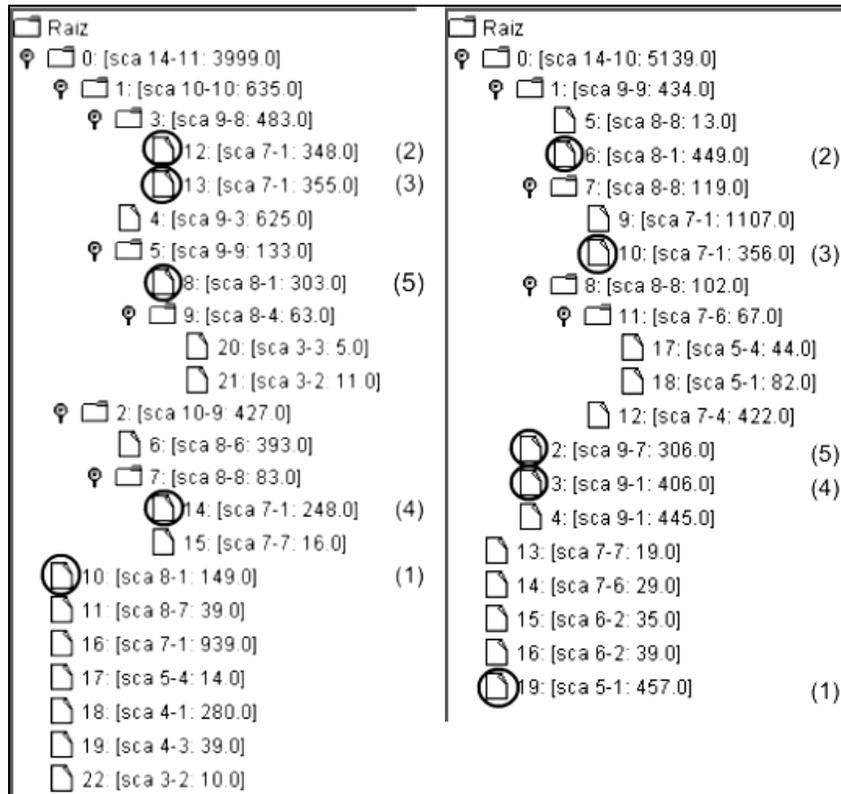


Figura 5.14. Árvores de SSPS obtida para as imagens image4 (esquerda), e image5 (direita) da figura 5.11

Ao contrário da árvore apresentada na figura 5.6, na qual o percurso da árvore é apresentado na vertical, na representação em árvore apresentada nas figuras 5.13 e 5.14, e em todas as árvores que serão apresentadas no capítulo de resultados, o percurso é lateral. Tome-se, por exemplo, a figura 5.13c, a partir do nó Raiz. Os nós mais abaixo e que estão diretamente ligados ao nó raiz são aqueles que não possuem um pai. O nó 0, por exemplo, que representa o SSBlob mais claro da escala 14 na figura 5.12.c, tem três filhos, os nós 3, 4 e 5. O nó 6 que também é diretamente ligado ao nó raiz representa a estrutura 6, que sobrevive até a escala 8. O pontos muito pequenos que aparecem nas escalas mais altas, por exemplo, nas escalas 10, 11 e 12, não tem qualquer representação na árvore porque o tamanho dos GLBlobs detectados é menor do que a resolução interna dessas escalas^{5.3}. Na parte inferior da árvore podem ser encontrados diversos nós que sobrevivem apenas em

^{5.3} Conforme apresentado no item 4.2.4 esses GLBlobs não são considerados na construção da árvore de SBlobs.

escalas muito baixas e, então, desaparecem. Essas estruturas representam a transição entre o fundo e o tórax.

Uma observação importante é em nenhum dos casos existe um ramo principal da árvore que contenha todas as estruturas, como o observado na figura 5.6. No conjunto de imagens [1,2,3], não existe sequer um ramo que possa ser chamado de principal e no conjunto de imagens [4,5], existe um conjunto principal, mas a estrutura 1 está sempre fora dele, pois devido à sua localização e contraste, o SSBlob que a representa sempre sofre um evento de destruição em níveis intermediários do espaço de escalas. A suposição feita no item 5.1, de que poderia haver sempre um ramo principal e que os objetos da imagem pertenceriam a esse ramo, não é válida. Assim, todos os ramos da árvore devem ser avaliados. A árvore da image3 possui apenas três níveis. Esse número aumenta a seis, para as imagens 4 e 5. Neste caso, esse aumento da profundidade reflete o fato da imagem ser formada por estruturas pequenas que se acoplam em novos SSBlobs em escalas intermediárias que, por sua vez irão se acoplar em novos SSBlobs.

No primeiro conjunto de imagens, existe uma estrutura que se destaca pela sua extensão— o fígado — que sempre é representado por um nó no primeiro nível da árvore. As estruturas 1 e 2, estruturas bem menores e que estão muito próximas, nos três casos se acoplam para formar uma estrutura que sobrevive até a última escala, e são encontradas nos níveis inferiores da árvore. As duas outras estruturas, embora menores, também são encontradas no primeiro nível da árvore, devido ao fato de que os SSBlobs são destruídos em escalas intermediárias. No segundo conjunto de imagens, o fato de as quatro estruturas maiores se acoplarem para formar uma estrutura, que sobrevive até a última escala, reflete-se no fato dos nós representando essas estruturas fazerem parte do ramo principal da árvore.

No amount of experimentation can ever prove me right; a single experiment can prove me wrong.

- Albert Einstein

Capítulo 6

Resultados

Neste capítulo, serão apresentados os resultados da aplicação do método proposto em imagens do *phantom* MCAT. Nos experimentos, é avaliada a influência de diversos parâmetros na construção da representação e no processo de identificação: a resolução da imagem original, o nível de ruído da imagem e o contraste entre a estrutura procurada e sua vizinhança.

6.1. Experimentos realizados

Foram realizados experimentos para avaliação do método apresentado no capítulo 5 em imagens bidimensionais, obtidas através da manipulação de cortes do *phantom* MCAT. O padrão para comparação da etapa final de identificação foi obtido aplicando-se o método à imagem original (sem ruído) de cada imagem usando o módulo *CriaPattern*. A tabela 6.1 sintetiza os experimentos realizados, mostrando o parâmetro avaliado no experimento, o número de imagens originais testadas e as variáveis acrescentadas à imagem original.

Tabela 6.1. Experimentos realizados

parâmetro	n° imagens	variáveis
resolução da imagem original	1	imagem original com diferentes resoluções construção do SSPS com valores diferentes de σ
ruído	5	imagens com 4 níveis de ruído diferentes
contraste	10	imagens com estruturas geométricas idênticas porém com contraste diferente entre as estruturas

Nos itens a seguir, cada tipo de experimento realizado será detalhado e os resultados obtidos serão apresentados.

6.2. Efeitos de diferentes resoluções

O primeiro parâmetro avaliado foi a resolução da imagem original. Este experimento tinha como objetivo verificar o comportamento do parâmetro volume do SSBlob, para estruturas idênticas em imagens com resolução original diferente. Além disso, pretendia-se avaliar as escalas de sobrevivência e verificar uma possível relação entre as escalas mais significativas dos SSPS para as diferentes resoluções. O objetivo era avaliar se o padrão pode ser utilizado em imagens tamanho original diferente e os valores esperados podem ser modificados a partir da aplicação de um ajuste nos valores.

As imagens com resolução original mais fina são avaliadas em mais de um espaço de escalas, construídos com diferentes valores de τ . Com isso pretende-se avaliar a influência do espaçamento dos níveis de escala na identificação das estruturas.

Para essa avaliação foi utilizada a imagem apresentada na figura 6.1. O método proposto foi aplicado a essa imagem em três resoluções da imagem original: 64x64, 128x128 e 256x256 pixels. Na figura 6.1 a imagem é apresentada na resolução 64 x 64 pixels, nela estão identificadas as quatro estruturas cujos volumes e escalas de sobrevivência serão avaliados.

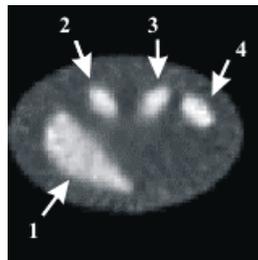


Figura 6.1. Imagem do *phantom* MCAT, com indicação das estruturas avaliadas.

6.2.1. Construção dos SSPS

Resolução 64 x 64

O SSPS da imagem apresentada na figura 6.1., com resolução de 64x64 pixels, foi construído utilizando $\tau = 0.19$. Os blobs no espaço de escalas e a árvore de SSPS são mostrados na figura 6.2.

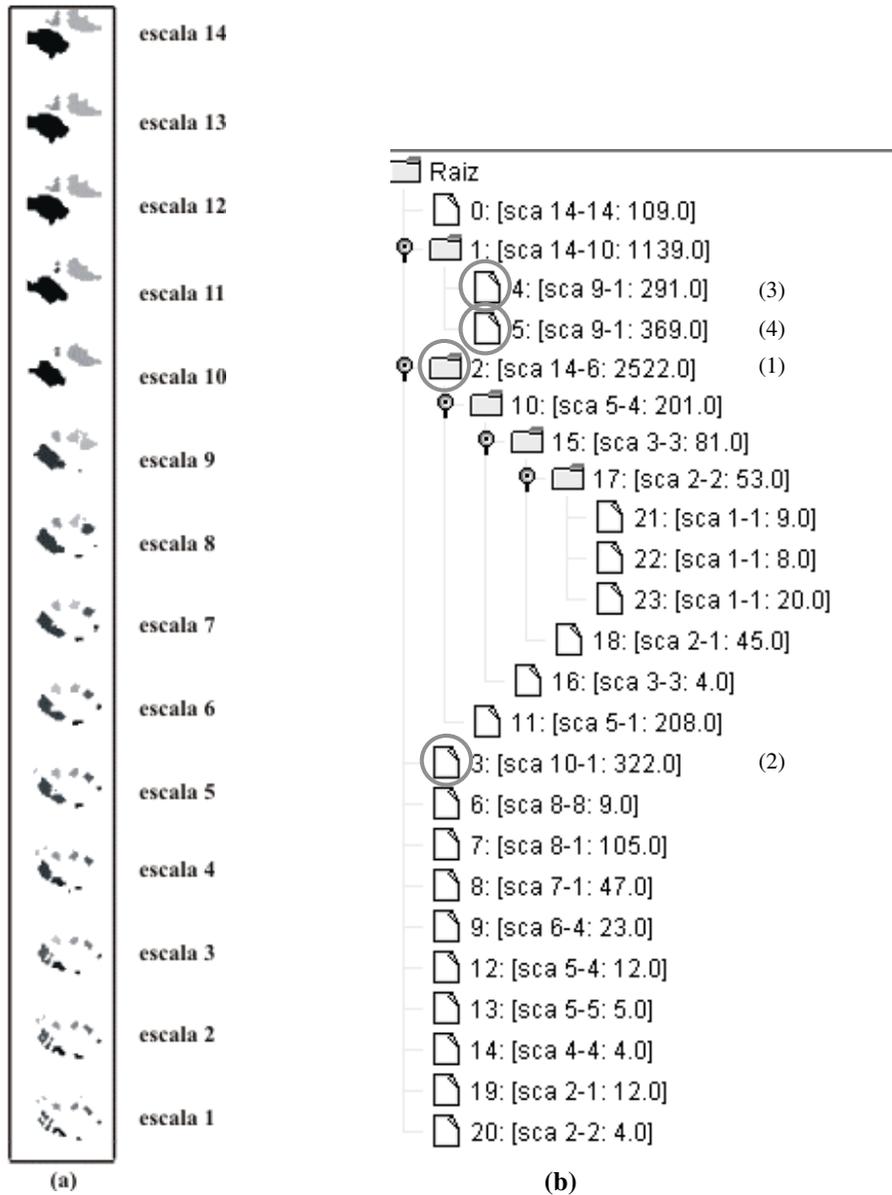


Figura 6.2. Espaço de escalas para a imagem apresentada em 6.1. com resolução 64x64. (a) Blobs no espaço de escalas, $\tau = 0,19$. (b) árvore de SSPS. São identificados na árvore os nós que correspondem aos órgãos na figura 6.1.

Resolução 128 x 128

Os SSPS da imagem apresentada na figura 6.1. com resolução de 128x128 pixels foram construídos utilizando $\tau = 0,19$ e $\tau = 0,22$ ^{6.1}. Os blobs no espaço de escalas e a árvore de SSPS são visualizados nas figura 6.3 e 6.4.

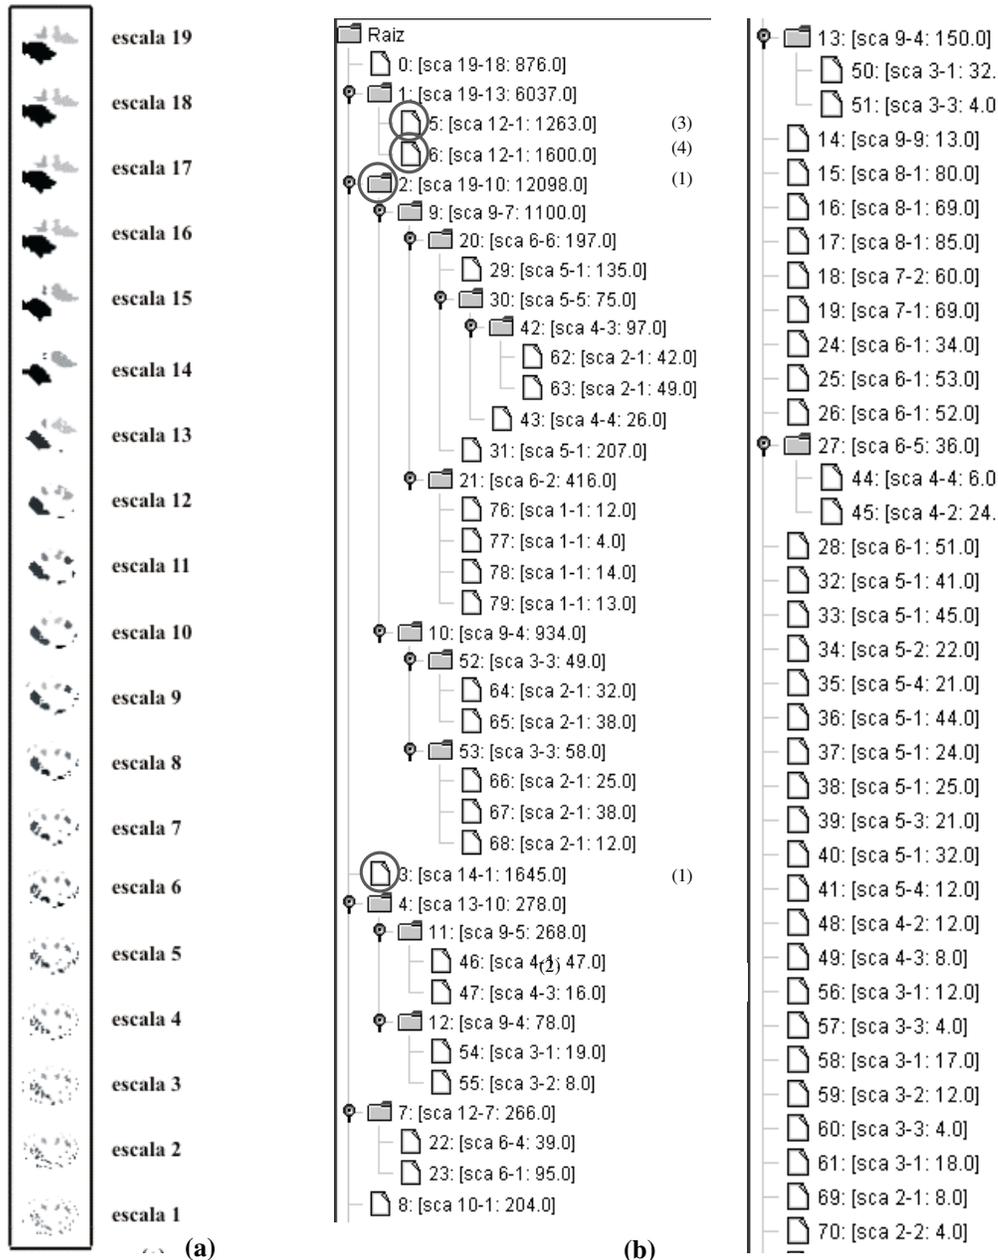


Figura 6.3. Espaço de escalas para a imagem apresentada em 6.1 com resolução 128x128. (a) Blobs no espaço de escalas, $\tau = 0,19$. (b) árvore de SSPS.

^{6.1} O valor de $\tau=0,22$ cria um espaço de escalas semelhante ao obtido para a resolução de 64 x 64, com $\tau = 0,19$.

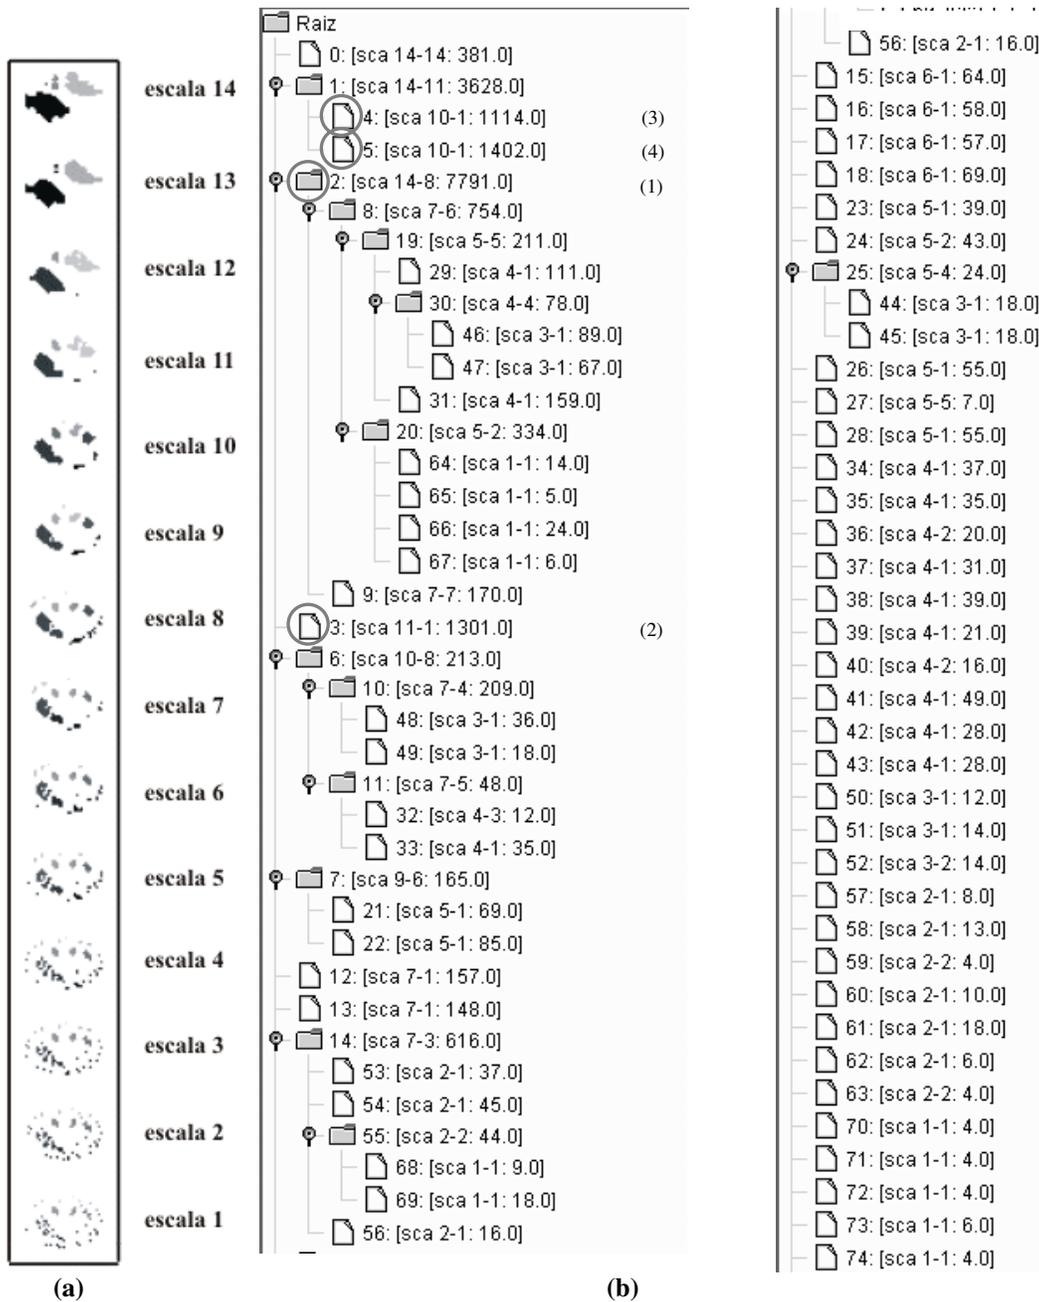


Figura 6.4. Espaço de escalas para a imagem apresentada em 6.1 com resolução 128x128. (a) Blobs no espaço de escalas, $\tau = 0,22$. (b) árvore de SSPS.

Resolução 256 x 256

Os SSPS da imagem apresentada na figura 6.1 com resolução de 256x256 pixels foram construídos utilizando $\tau = 0,19$, $\tau = 0,22$ e $\tau = 0,25$ ^{6.2}. Os blobs no espaço de escalas e a árvore de SSPS com $\tau = 0,19$ são mostrados nas figura 6.5 e 6.6. A figura 6.5 apresenta apenas os nós do primeiro nível. A figura 6.6 apresenta a árvore de SSBlobs em detalhes. Nas figuras 6.7 e 6.8 apresentam-se os resultados para $\tau = 0,22$. E na figura 6.9 é mostrada a árvore de SSBlobs para $\tau = 0,25$.

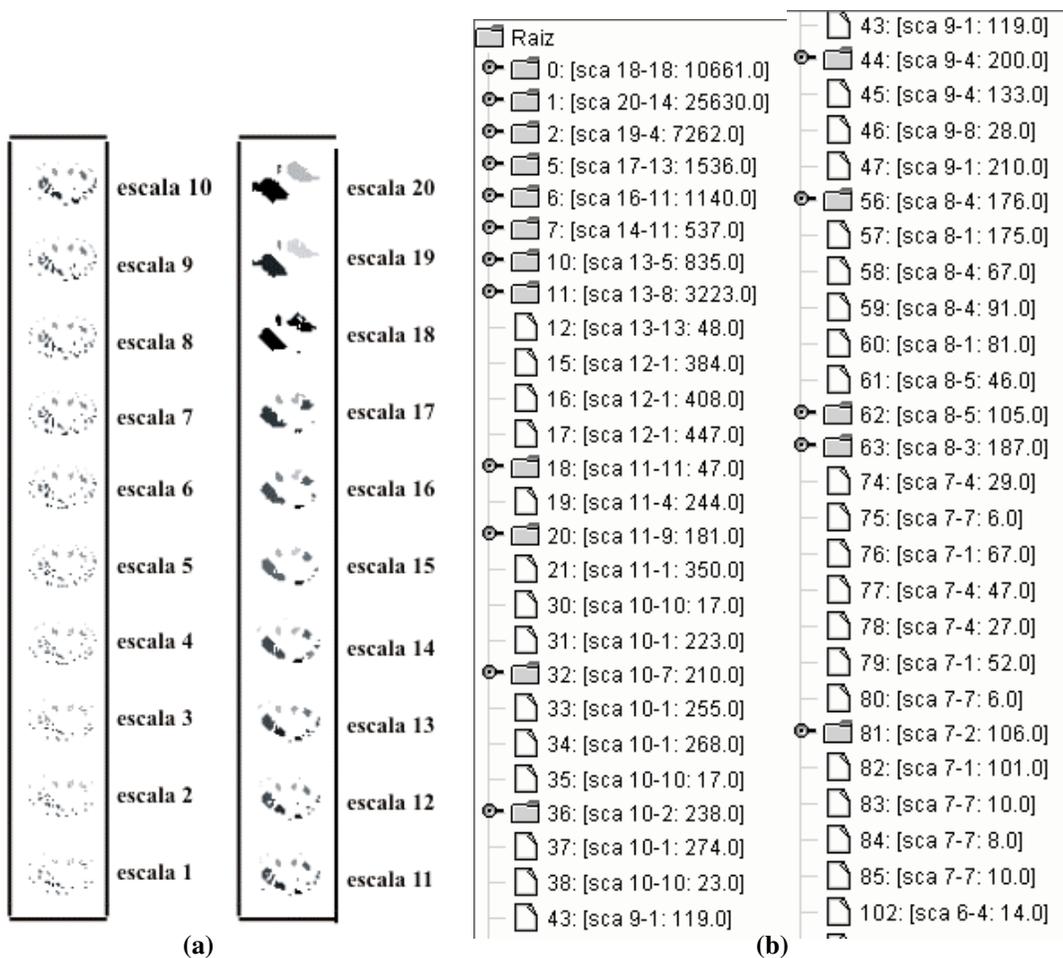


Figura 6.5. Espaço de escalas para a imagem apresentada em 6.1 com resolução 256x256. (a) Blobs no espaço de escalas, $\tau = 0,19$. (b) árvore de SSPS, na qual são mostrados apenas os nós do primeiro nível.

^{6.2} O valor de $\tau=0,25$ cria um espaço de escalas semelhante ao obtido para a resolução de 128 x 128, com $\tau=0,22$, ou para a resolução de 64 x 64 com $\tau=0,19$.

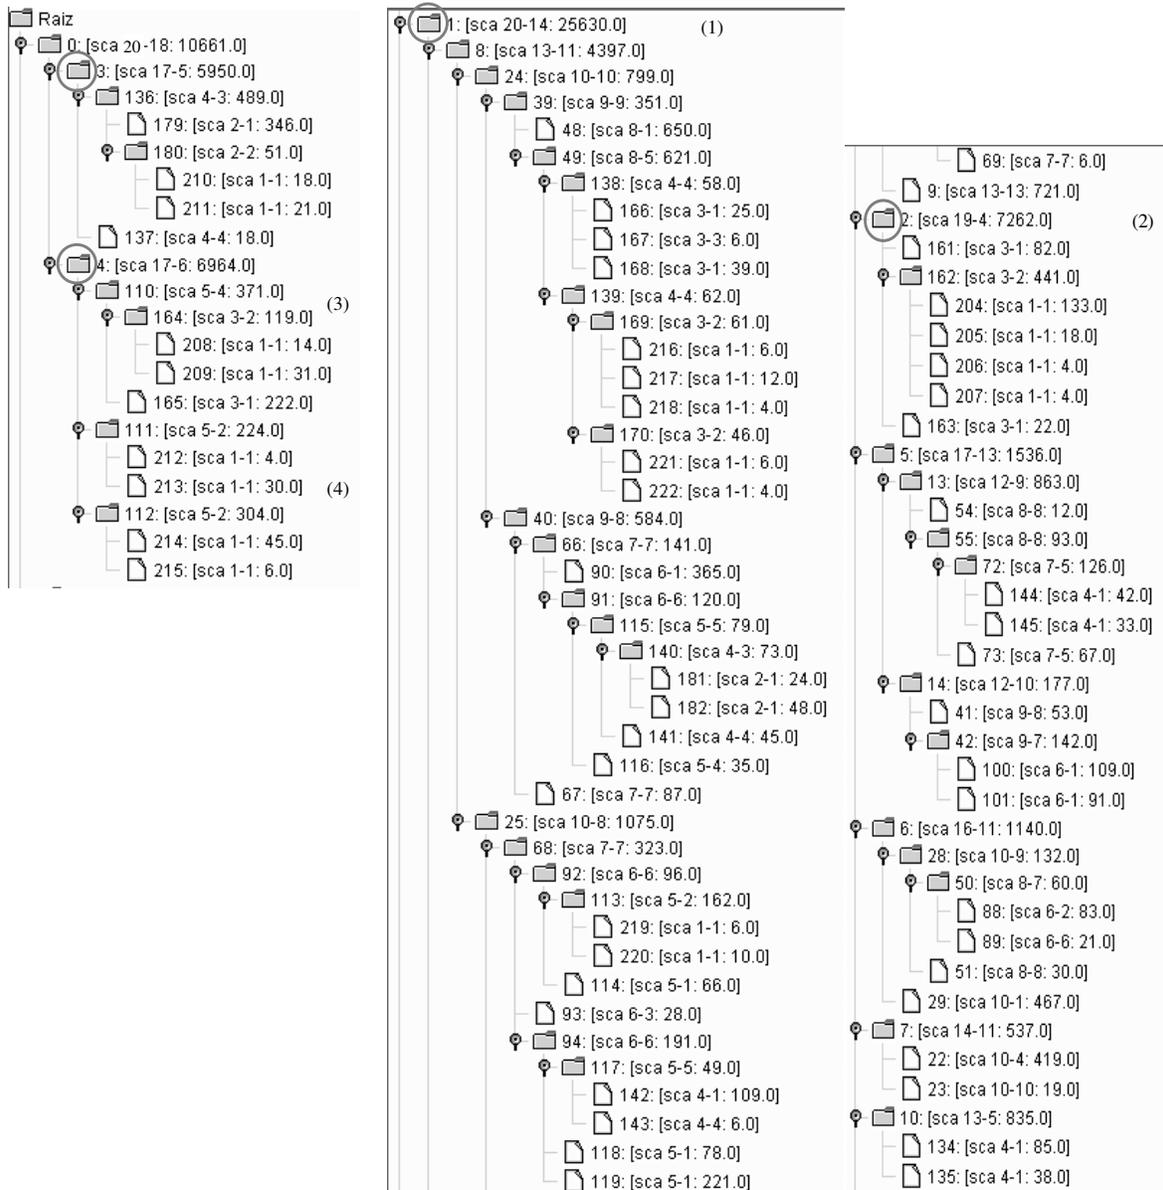


Figura 6.6. Detalhe da árvore de SSPS apresentada na figura 6.5.b.

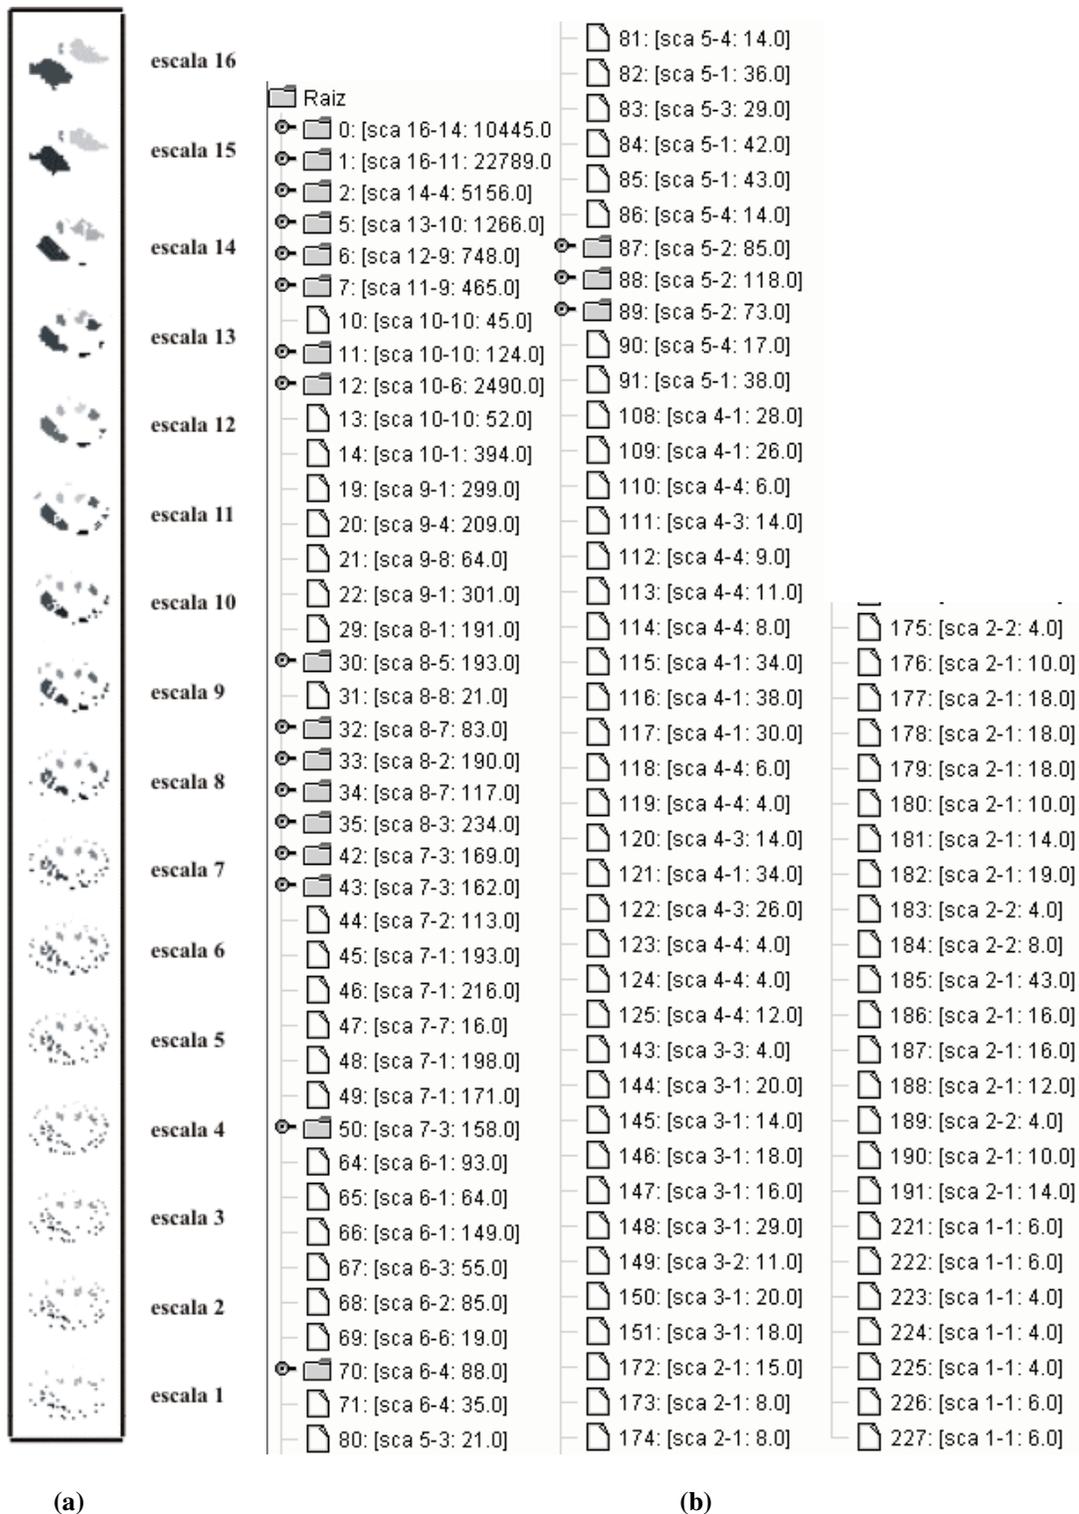


Figura 6.7. Espaço de escalas para a imagem apresentada em 6.1 com resolução 256x256. (a) Blobs no espaço de escalas, $\tau = 0,22$. (b) árvore de SSPP, na qual são mostrados apenas os nós do primeiro nível.



Figura 6.8. Detalhe da árvore de SSPS apresentada na figura 6.7.b. Neste detalhe, apresentam-se os ramos da árvore filhos dos nós 0, 1 e 2.

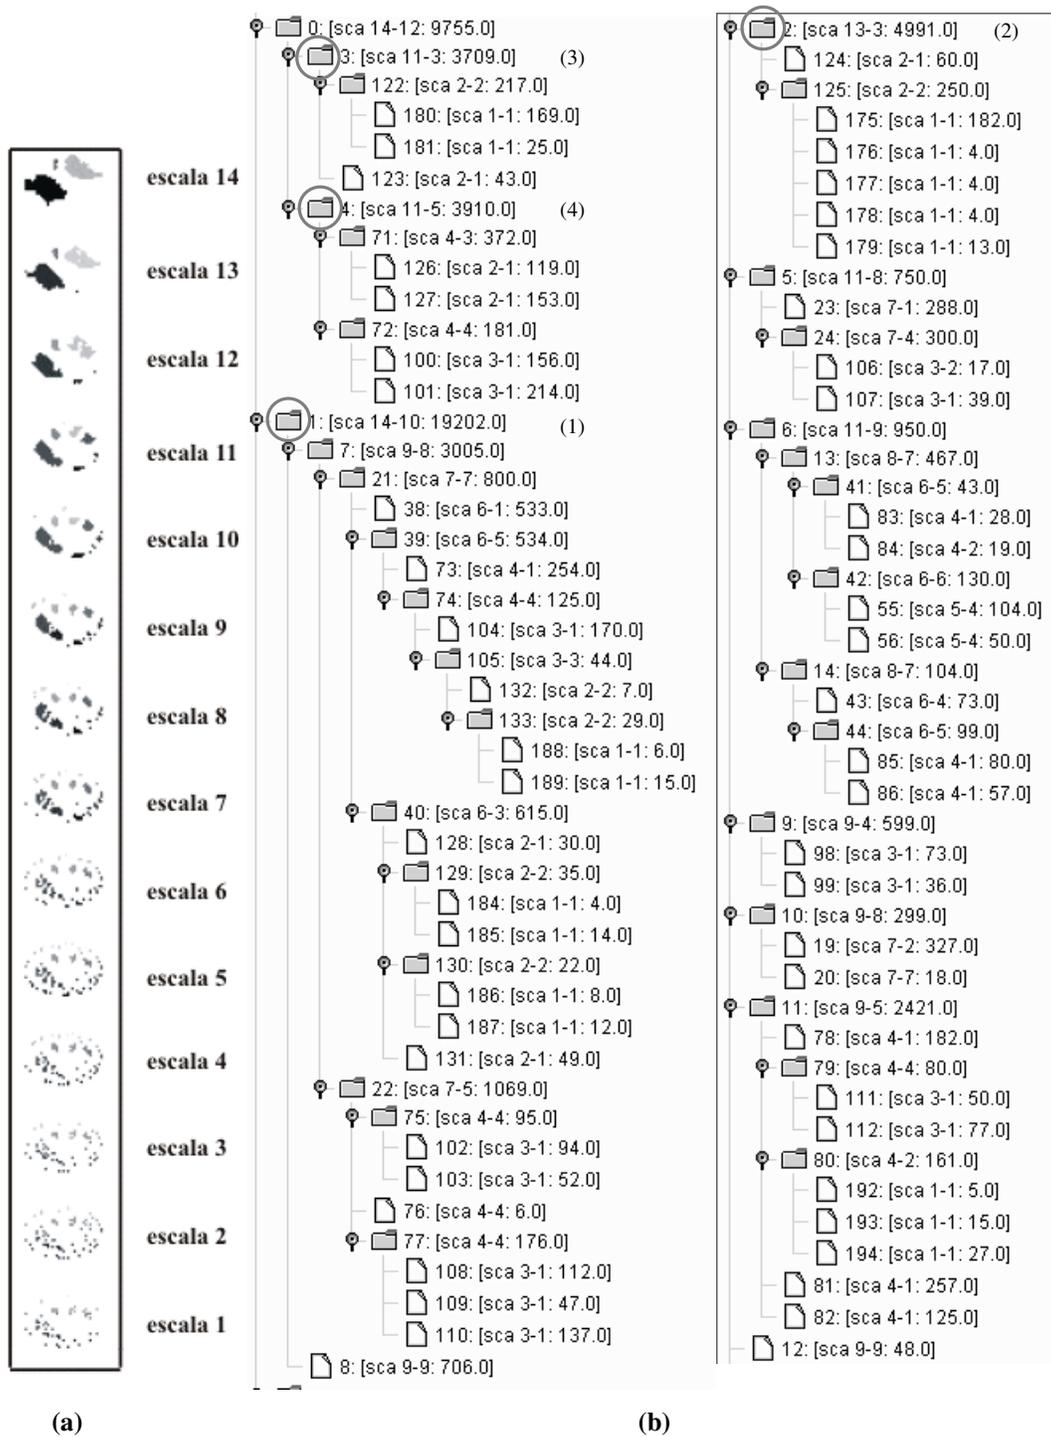


Figura 6.9. Espaço de escalas para a imagem apresentada em 6.1 com resolução 256x256. (b) Blobs no espaço de escalas, $\tau = 0,25$. (a) árvore de SSPPs.

6.2.2. Comparação dos parâmetros nas diversas resoluções

A tabela 6.2 apresenta os valores de volume total dos SSBlobs, obtidos para cada uma das estruturas mostradas na figura 6.1, nas diferentes escalas e valores de τ . A figura 6.10 mostra as relações entre os volumes de SSBlob para as quatro estruturas para os diversos espaços de escala e a figura 6.11 mostra a mesma informação para espaços de escala construídos a partir do mesmo conjunto de imagens sem ruído.

Tabela 6.2. Volumes (em pixels) encontrados para as quatro estruturas nas diferentes resoluções e com espaços de escala construídos a partir de parâmetros distintos

estrutura	64x64 ($\tau = 0,19$)	128x128 ($\tau = 0,19$)	128x128 ($\tau = 0,22$)	256x256 ($\tau = 0,19$)	256x256 ($\tau = 0,22$)	256x256 ($\tau = 0,25$)
1	2 522	12 098	7 791	25 630	22 789	19 202
2	322	1 645	1 301	7 262	5 156	4 991
3	291	1.263	1 114	5 950	4 700	3 709
4	369	1 600	1 402	6 964	5 120	3 910

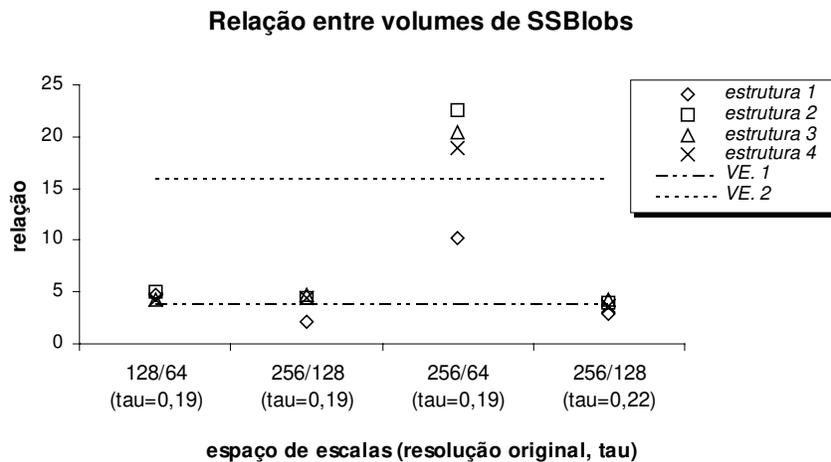


Figura 6.10. Razão entre os volumes para espaços de escala da imagem apresentada em 6.1, obtidos a partir de diferentes resoluções e construídos utilizando 2 valores de τ . O valor esperado 1 (VE.1) para a razão entre os volumes nas resoluções 256/64 é 16 e o valor esperado 2 (VE.2) para a razão entre os volumes nas resoluções 256/128 (para os dois valores de τ) e 128/64 é 4.

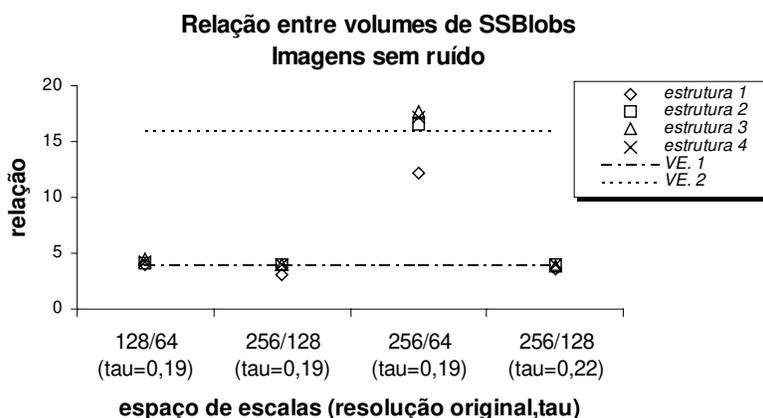


Figura 6.11. Razão entre os volumes para espaços de escala, sem ruído.

Verifica-se que a variação do volume obtida experimentalmente não corresponde ao valor esperado, especialmente para a estrutura 1. Isso provavelmente ocorre porque a maior estrutura da imagem tem uma variação grande na escala de aparecimento, causada pelas suas inhomogeneidades internas. O desvio em relação ao valor esperado se torna mais acentuado na relação entre os valores obtidos nas resoluções 256x256 e 64x64. O objetivo da análise de relação entre os volumes era verificar a possibilidade da criação de um padrão genérico, independente da resolução da imagem. Como a resolução da imagem original faz parte das informações do padrão, os dados de volume e distância poderiam ser ajustados de acordo com a nova resolução. Entretanto, os resultados obtidos mostram que o parâmetro volume não varia da forma esperada para algumas estruturas. Portanto, na aplicação desenvolvida neste protótipo, não é possível determinar um padrão independente da resolução original da imagem. Os outros parâmetros utilizados para o casamento de estruturas, as distâncias e os ângulos, se mostram, em princípio, mais adequadas nesse sentido, pois os ângulos são invariantes em relação à escala original e as distâncias são proporcionais a ela. Esse resultado mostra, mais uma vez, que parâmetros que reflitam o contexto da cena na qual a estrutura procurada está inserida são mais robustos e devem ser utilizados para a identificação.

Foi avaliado, também, o comportamento dos blobs em termos de sobrevivência nas escalas e da escala mais adequada para processamento nos diferentes experimentos. A análise direta da escala mais apropriada não forneceu indícios da possibilidade de encontrar

uma relação mais genérica para o padrão. Entretanto, a análise das faixas de sobrevivência mostrou um comportamento bastante similar para as diferentes resoluções, que poderia permitir o estabelecimento de alguma relação entre elas. Assim, considera-se que os resultados não são conclusivos sob este aspecto, que necessita de mais experimentos e análises que permitam uma análise mais acurada. Em um experimento ideal, as imagens devem ser adquiridas com resoluções originais diferentes. No experimento exposto neste item, partiu-se de uma imagem com resolução inicial de 64 x 64 pixels e, a partir dela, foram geradas as imagens com resoluções mais finas, utilizando uma funcionalidade do software AVS. Entretanto, no processo de re-escalonamento da imagem, o software já efetua um processamento (interpolação) para determinar os valores de intensidade de cada elemento da imagem, o que gera valores distintos dos obtidos em uma aquisição real.

6.2.3. Redução da árvore baseada em volume do SSBlob

Apresentam-se, neste item, os resultados obtidos com a redução da árvore para a identificação de todos os órgãos da imagem 6.1. Foram considerados nós candidatos aqueles cujo volume de SSBlob tivesse uma variação em relação ao padrão menor do que $\pm 20\%$. O principal objetivo era verificar se a utilização desse critério pode eliminar o nó que representa a estrutura de interesse da segunda fase de casamento de padrões.

Estrutura 1

Todas as pesquisas utilizando os volumes computados na tabela 6.2 forneceram apenas um único nó como possível candidato. Como essa estrutura é muito diferenciada em termos de tamanho em relação às demais, esse resultado não surpreende. Para o caso de detecção dessa estrutura, o parâmetro volume do SSBlob seria suficiente para sua identificação. Essa é uma observação interessante, pois se verifica que mesmo utilizando um parâmetro simples seria possível identificar uma estrutura importante da imagem.

Estruturas 2, 3 e 4

As figuras 6.15, 6.16 e 6.17 mostram, à esquerda, o trecho inicial das árvores de SSBlobs e à direita a árvore reduzida, após a aplicação do casamento de volume do SSBlob, para as estruturas 2, 3 e 4, respectivamente.

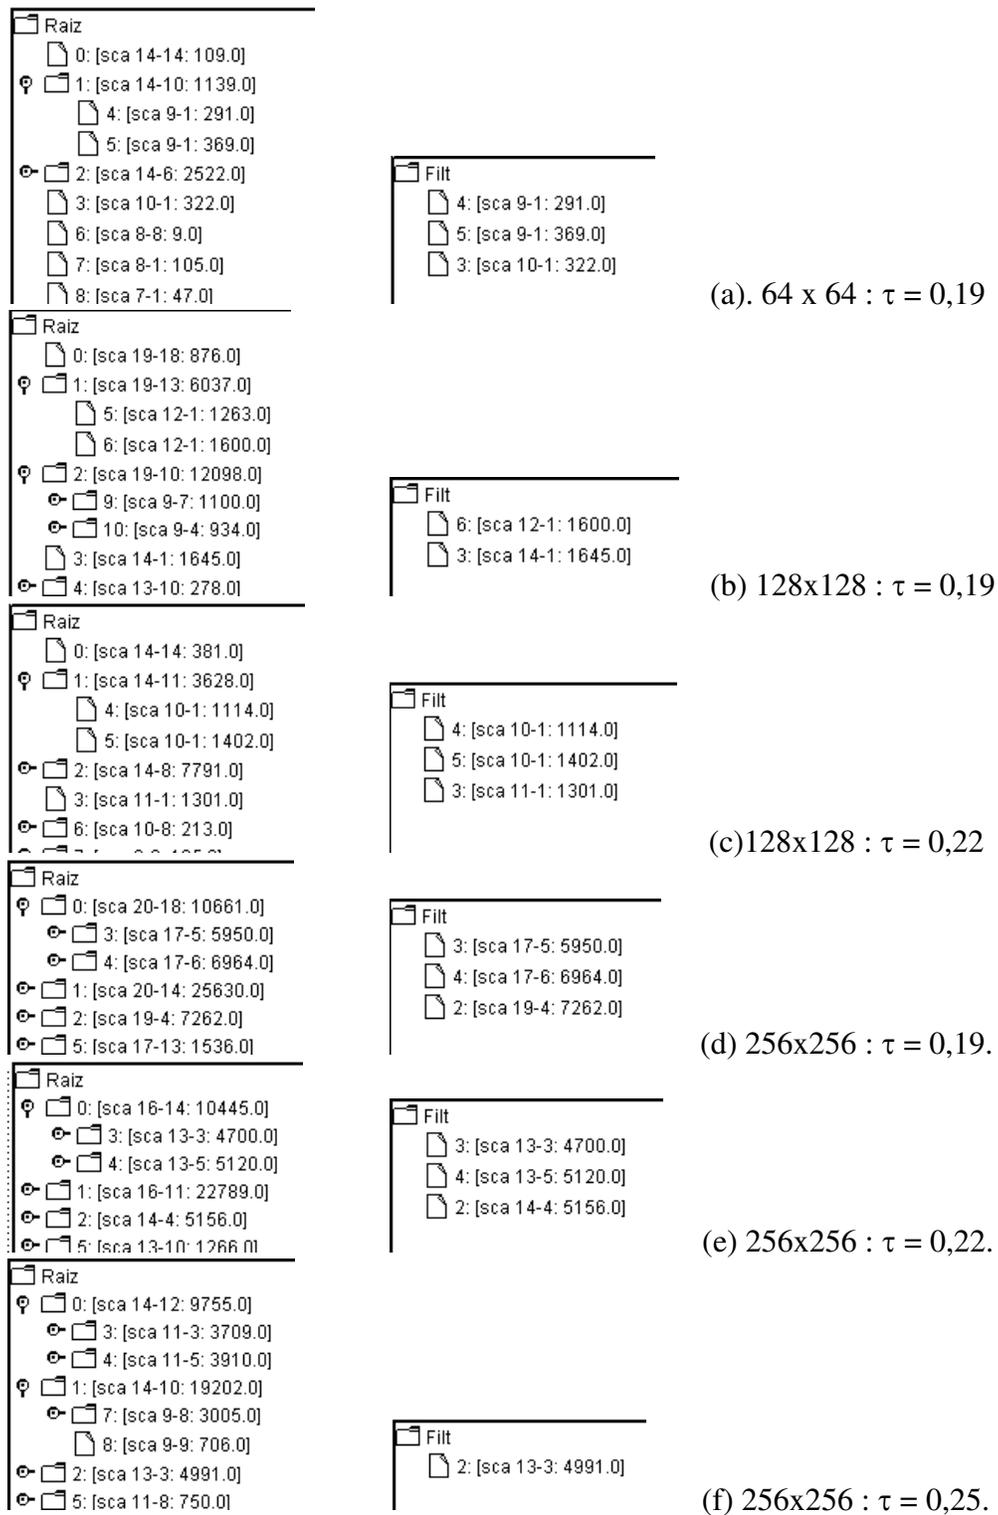


Figura 6.12. Redução da árvore de SSBlobs pela aplicação do casamento utilizando o parâmetro volume do SSBlob para a estrutura 2.

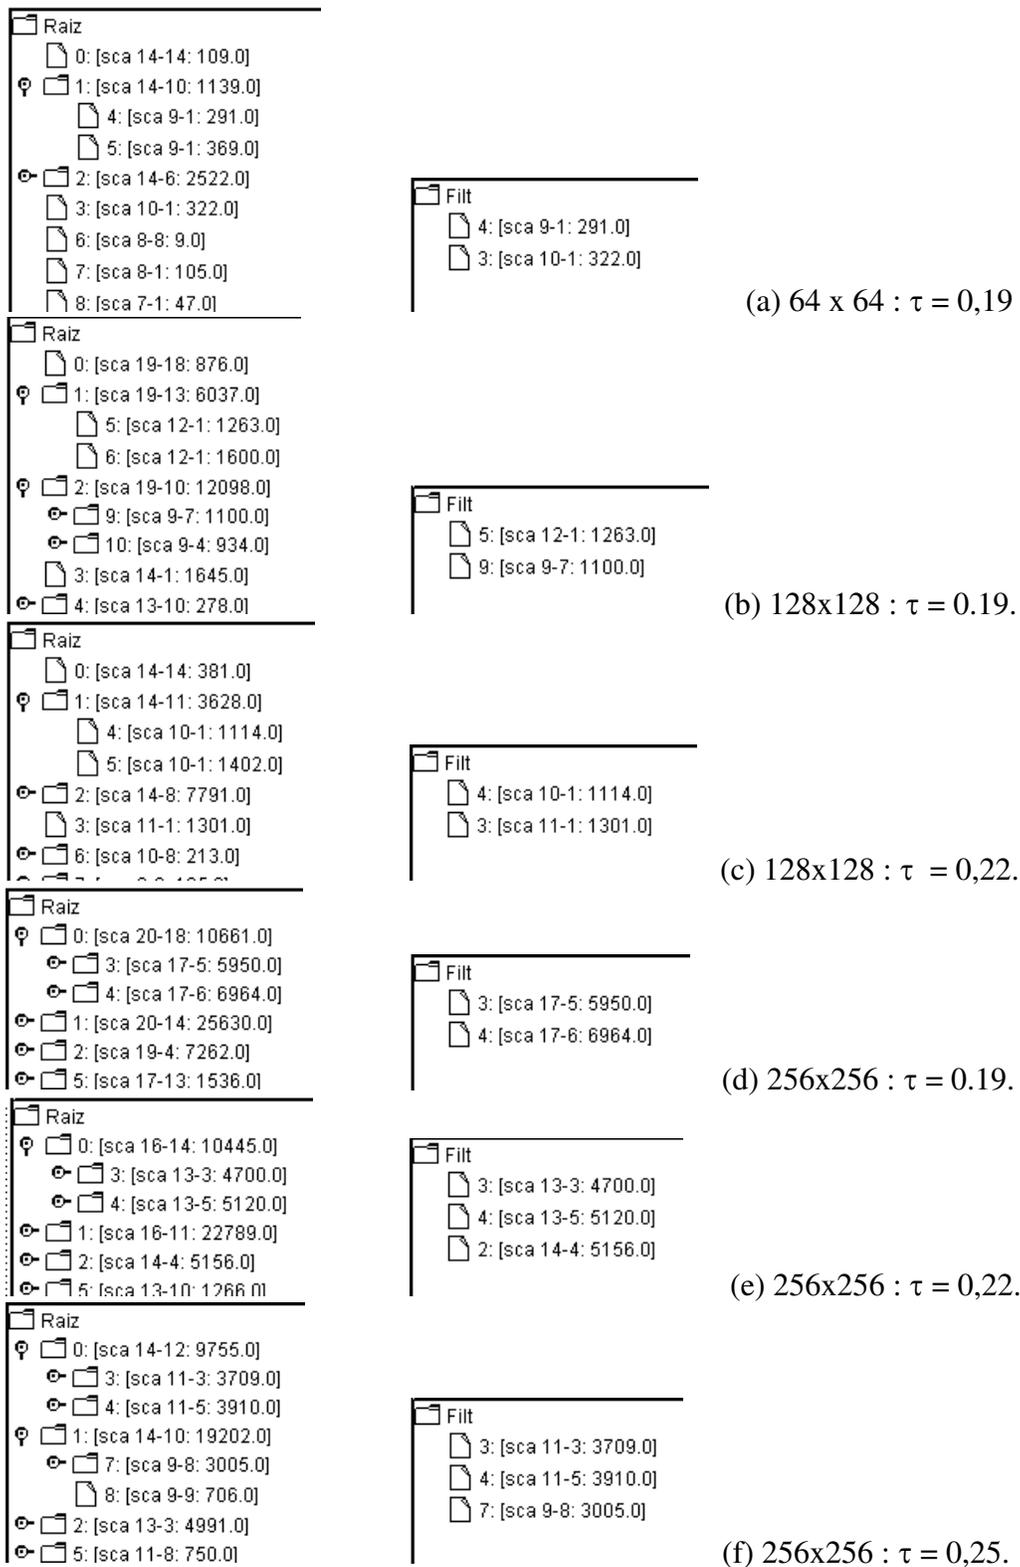


Figura 6.13. Redução da árvore de SSBlobs pela aplicação do casamento utilizando o parâmetro volume do SSBlob para a estrutura 3.

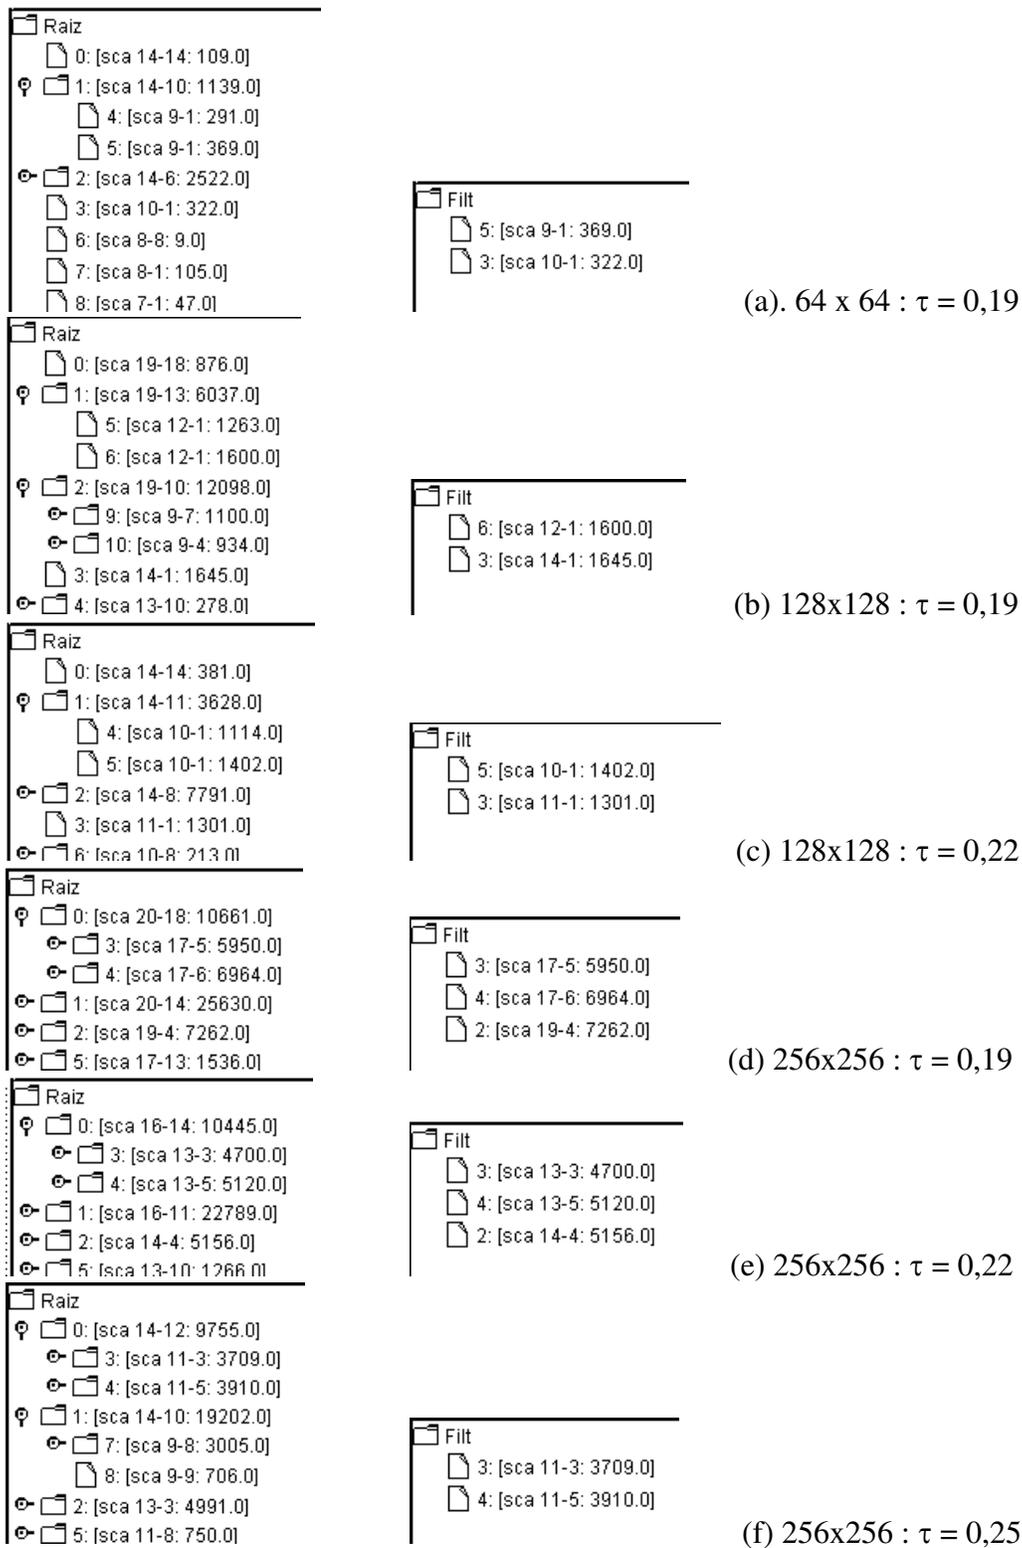


Figura 6.14. Redução da árvore de SSBlobs pela aplicação do casamento utilizando o parâmetro volume do SSBlob para a estrutura 4.

Após a redução da árvore, a aplicação da segunda fase do casamento de estruturas, utilizando informações geométricas, identificou corretamente todas as estruturas. As figuras 6.12, 6.13 e 6.14 mostram a enorme redução no espaço de busca para a segunda fase de casamento de estruturas, conseguida pela redução das árvores baseada no parâmetro volume de SSBlob. Para o exemplo apresentado neste experimento, a utilização da faixa de variabilidade permitida de $\pm 20\%$ em relação ao padrão não eliminou nenhum nó que identifica uma estrutura real. Não se pode, entretanto, generalizar este resultado para qualquer imagem, ou nível de contraste ou ruído. Nos próximos experimentos, para os quais serão apresentados os resultados do casamento de padrões, será observado se esse resultado continua válido. Neste experimento, o padrão para identificação de cada estrutura foi obtido a partir das imagens sem ruído.

6.3. Imagens com níveis de ruído diferentes

Para avaliar a influência do ruído na aplicação do método proposto, foi acrescentado ruído gaussiano aditivo em três níveis diferentes às imagens originais (sem ruído) com resolução de 64 x 64 pixels, apresentadas na Figura 5.11. A tabela 6.3 apresenta os valores de desvio padrão nas contagens das imagens originais e das imagens de ruído, bem como os valores da relação sinal-ruído, em decibéis, para os cinco conjuntos de imagens criados.

Tabela 6.3. Parâmetros das imagens geradas com diferentes níveis de ruído. “ σ_{sinal} ” é o desvio padrão da intensidade, obtido para todos os elementos da imagem original; “ $\sigma_{\text{ruído}}$ ” é o desvio padrão da imagem de ruído. O nível de ruído é caracterizado pela SNR, a razão sinal-ruído, dada pela equação 6.1.

imagem	σ_{sinal}	ruído baixo		ruído médio		ruído alto	
		$\sigma_{\text{ruído}}$	SNR	$\sigma_{\text{ruído}}$	SNR	$\sigma_{\text{ruído}}$	SNR
imagem1	738	16,9	32,8	86,3	18,5	287,6	8,0
imagem2	647	14,7	32,9	75,3	18,7	259,8	7,9
imagem3	525	12,0	32,8	60,1	18,8	210,9	7,9
imagem4	583	13,4	32,8	66,9	18,8	233,8	7,9
imagem5	475	11,1	32,7	54,4	18,8	188,2	8,0

Na tabela 6.3, são utilizados os parâmetros: σ_{signal} = desvio padrão da imagem original; $\sigma_{\text{ruído}}$ = desvio padrão da imagem de ruído; SNR = razão sinal-ruído. Para caracterização do nível de ruído, utilizou-se a expressão de Rangayan (2005):

$$\text{SNR} = 20 * \log_{10} \left[\frac{\sigma_{\text{signal}}}{\sigma_{\text{ruído}}} \right] \quad (6.1)$$

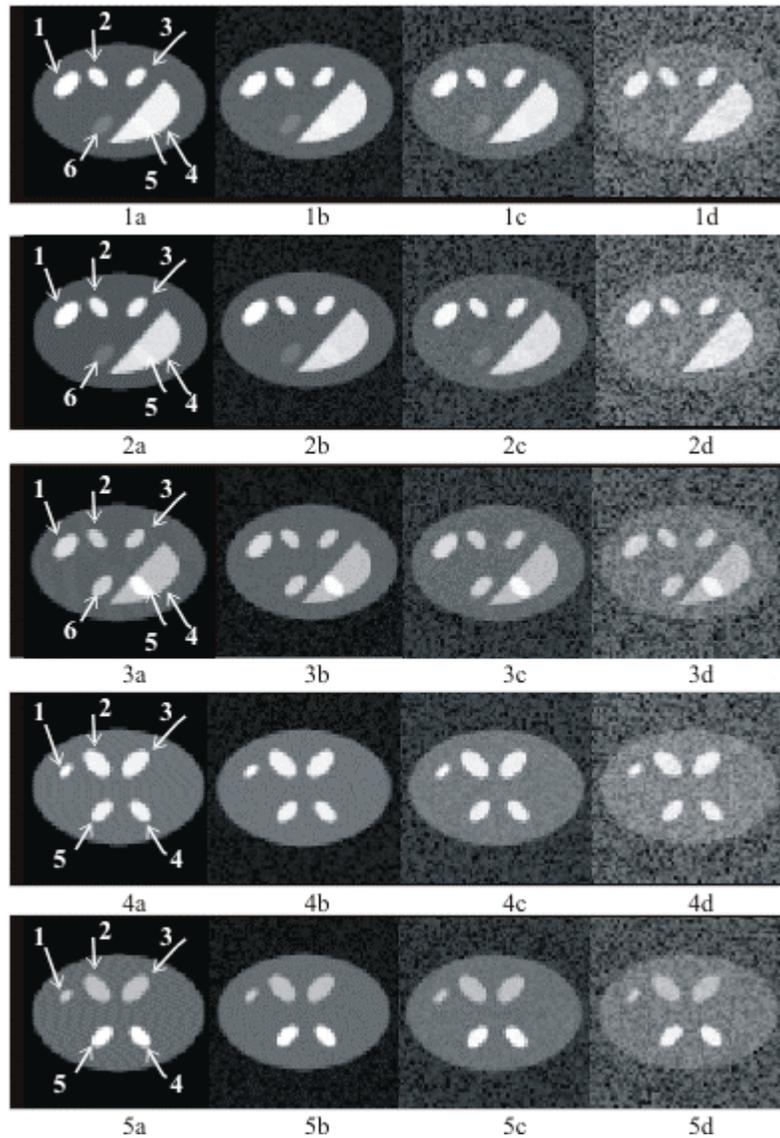


Figura 6.15. Conjunto de cinco imagens com diferentes níveis de ruído. A coluna (a) apresenta as imagens originais sem ruído, a coluna (b) a imagem de ruído baixo, a coluna (c) a imagem de ruído médio e a coluna (d) a imagem de ruído alto.

As imagens com adição de ruído são apresentadas na figura 6.15. São apresentadas as cinco imagens originais (coluna a) e com adição de três níveis de ruído: baixo (coluna b), médio (coluna c) e alto (coluna d). As figuras 6.16 a 6.18 apresentam os blobs detectados nos espaços de escalas construídos para as cinco imagens originais sem ruído e para as mesmas imagens somadas com três níveis de ruído diferentes, com $\tau = 0,19$. Os tempos para construção dos SSPS dos cinco conjuntos de imagens variou entre 2 e 12 segundos.

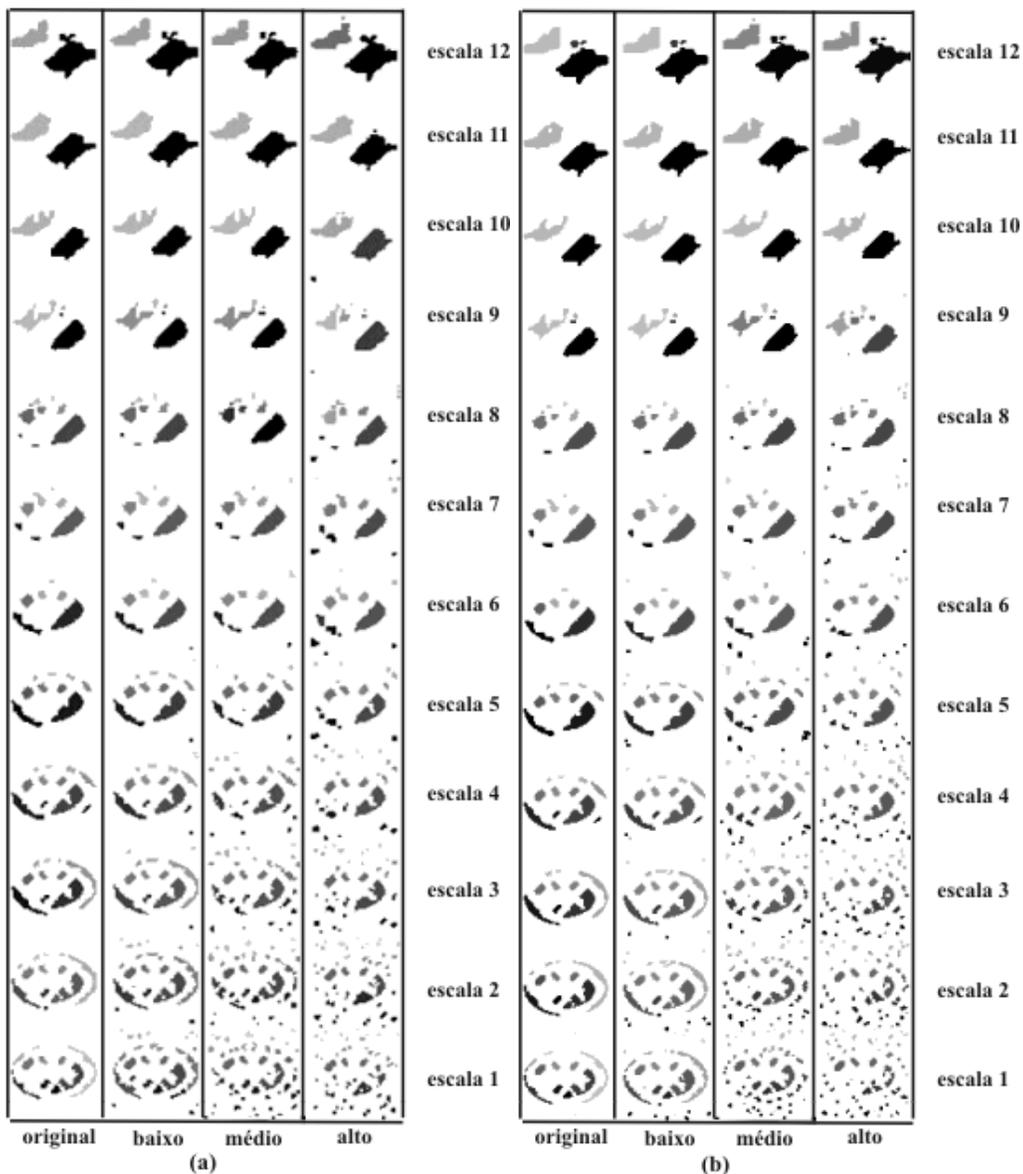


Figura 6.16. Blobs detectados nos espaços de escala das imagens image1 (a) e image2 (b), obtidos com $\tau = 0,19$. Escala mais adequada para identificação da estrutura 2 nos dois conjuntos: 7.

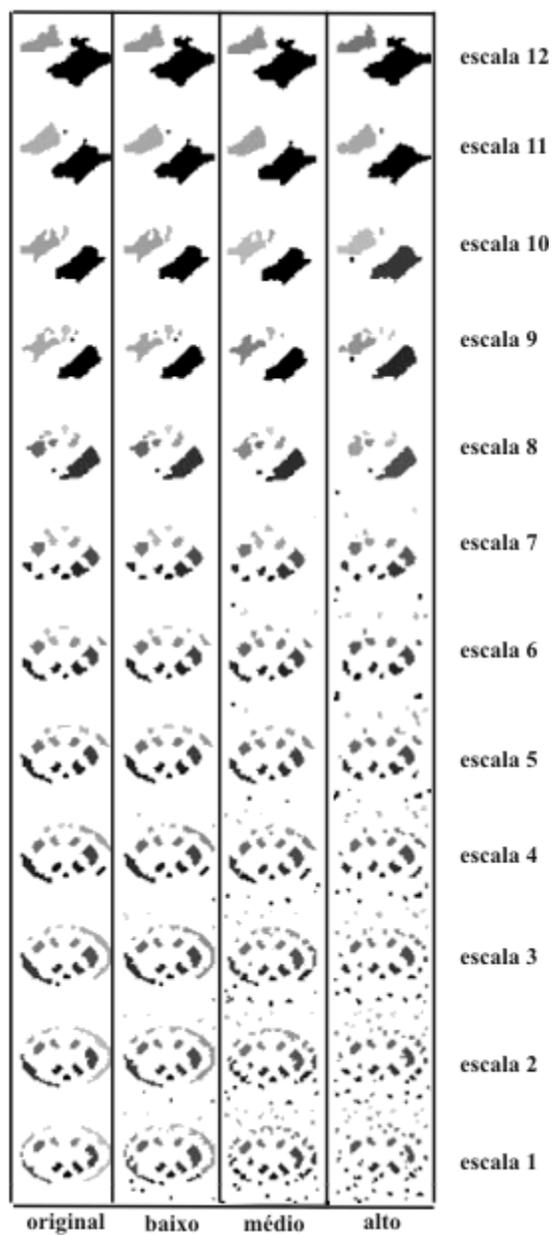


Figura 6.17. Blobs detectados nos espaços de escala da imagem3, obtidos com $\tau = 0,19$. Escala mais adequada para detecção da estrutura 2: 6.

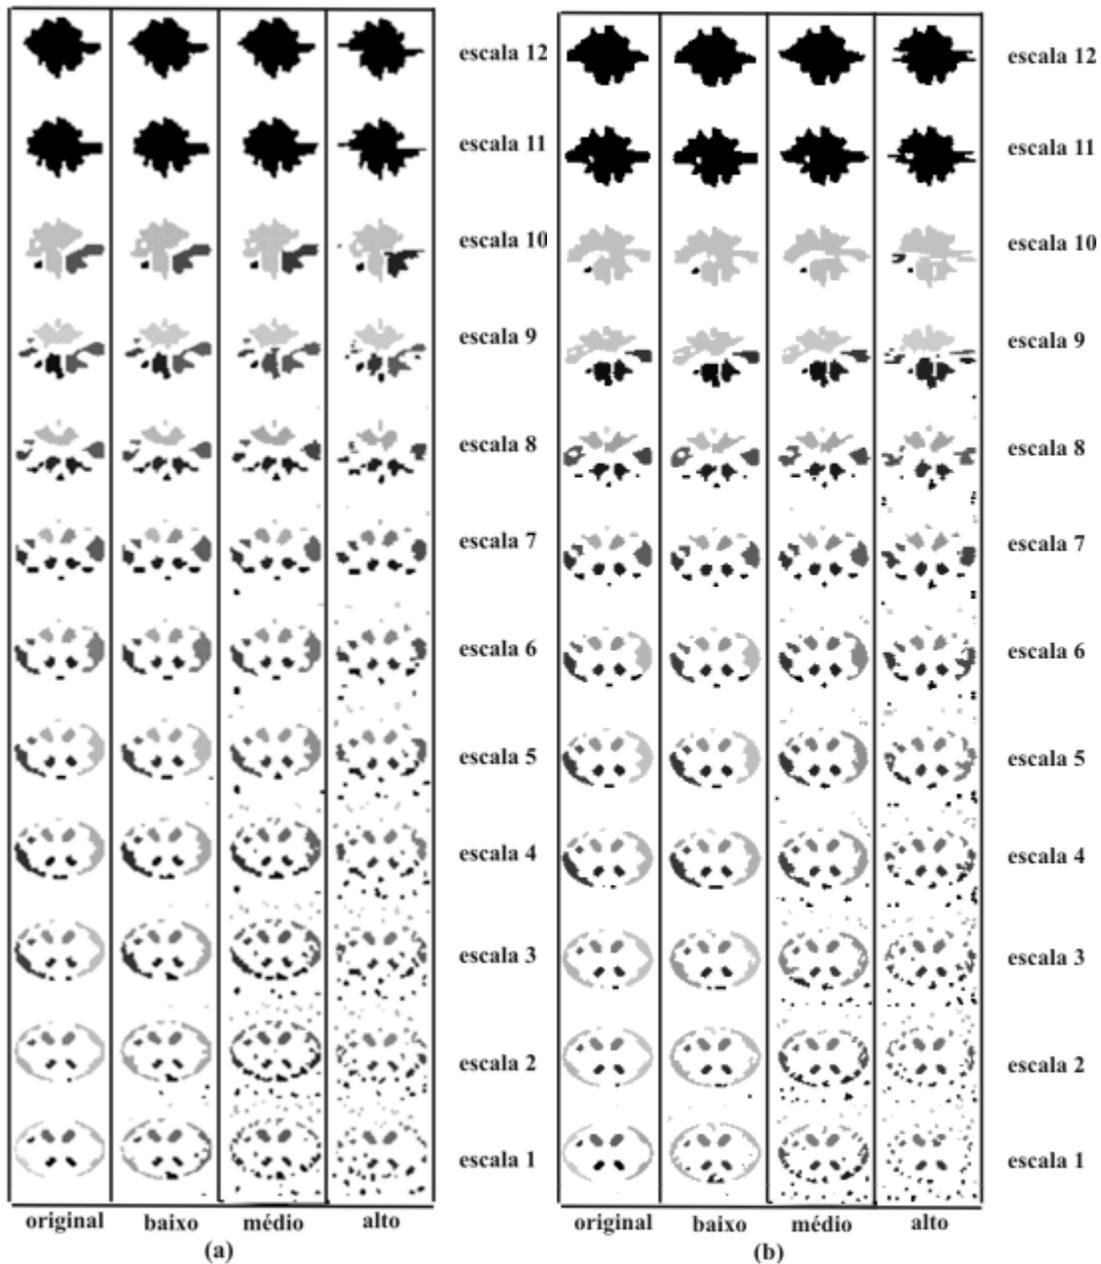


Figura 6.18. Blobs detectados nos espaços de escala das imagens image4 (a) e image5 (b), obtidos com $\tau = 0,19$. Escala mais adequada para detecção da estrutura 5 nos dois conjuntos: 7.

A primeira observação que surge na análise dos SSPS das imagens com adição de ruído é que a quantidade de estruturas detectadas nas escalas mais baixas aumenta muito à medida em que aumenta o nível de ruído. Esse excesso de estruturas sem significado real

torna essas escalas inadequadas para o processamento da imagem. Da mesma forma que ocorre com o operador *umbilicity*, a aplicação de outros operadores em escalas baixas gera uma quantidade muito grande de resultados espúrios. Pode-se, ainda, verificar em todas as imagens que, nas escalas mais altas o comportamento dos SSBlobs é o mesmo, independente do nível de ruído. Esse é um resultado esperado, pois um dos objetivos da abordagem de espaço de escalas é a eliminação do ruído e manutenção das estruturas importantes nas escalas mais altas.

A inclusão do ruído nas imagens também influencia os resultados nas estruturas com baixo contraste. A estrutura 6 na imagem 2, caracterizada por seu contraste muito baixo, não é detectada no conjunto com alto ruído.

As cinco imagens originais foram divididas em dois grupos, de acordo com as estruturas geométricas presentes. Para avaliar a eficiência da etapa de casamento de padrões, foi escolhida uma estrutura de cada um dos dois grupos de imagens, mostrados na figura 6.19. No conjunto 1, foi escolhida a estrutura 2 e, no conjunto 2 foi escolhida a estrutura 5

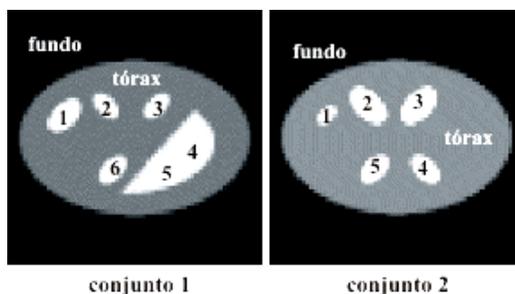


Figura 6.19. Imagens utilizadas para identificação de estruturas.

O tempo de processamento para o casamento de estruturas de todas as imagens foi inferior a 1s. Na tabela 6.4, apresentam-se os resultados obtidos para a identificação das estruturas pela aplicação do método proposto. Nessa tabela, \checkmark indica resultado correto na identificação e X representa resultado incorreto.

A aplicação do método proposto ao conjunto de imagens obteve sucesso na identificação das estruturas procuradas na maioria dos experimentos (87% de acerto), utilizando, na fase de redução da árvore, uma faixa de variação permitida no volume de

SSBlob, em relação ao padrão, de $\pm 20\%$. As exceções foram as imagens 1 e 5 com ruído alto. No caso da imagem 5, o SSBlob correto foi determinado quando a faixa de variação foi ampliada para $\pm 50\%$. Verificou-se que isto ocorreu devido à eliminação do nó que representa a estrutura procurada com a faixa de variação permitida para o volume de SSBlob em $\pm 20\%$. Este resultado mostra que a escolha da faixa a ser utilizada depende do conteúdo ou estruturas presentes imagens. Optou-se por avaliar a utilização das duas faixas, $\pm 20\%$ e $\pm 50\%$, em todas as imagens deste e do próximo experimento. A utilização da faixa de $\pm 50\%$ elevou o índice de resultados corretos para 93%.

Tabela 6.4. Resultados da etapa final de identificação dos nós do SSPS para as imagens com três níveis de ruído diferentes. As duas colunas para cada nível de ruído indicam a faixa de variação permitida no volume de SSBlob, em relação ao padrão, na etapa de simplificação da árvore. \checkmark indica resultado correto na identificação e X representa resultado incorreto.

imagem	ruído baixo		ruído médio		ruído alto	
	$\pm 20\%$	$\pm 50\%$	$\pm 20\%$	$\pm 50\%$	$\pm 20\%$	$\pm 50\%$
imagem1	\checkmark	\checkmark	\checkmark	\checkmark	X	X
imagem2	\checkmark	\checkmark	\checkmark	\checkmark	\checkmark	\checkmark
imagem3	\checkmark	\checkmark	\checkmark	\checkmark	\checkmark	\checkmark
imagem4	\checkmark	\checkmark	\checkmark	\checkmark	\checkmark	\checkmark
imagem5	\checkmark	\checkmark	\checkmark	\checkmark	X	\checkmark

6.4. Contraste de estruturas

Conforme já foi verificado em experimentos anteriores, e também na formulação teórica, o contraste é um dos fatores para a sobrevivência de uma estrutura em um número maior ou menor de níveis de escala. Esse comportamento afeta a construção do SSPS. Deseja-se avaliar, neste item, a resposta do método de identificação em diferentes níveis de contraste e, para cada nível de contraste, em diferentes níveis de ruído. Para isso, foi criada uma imagem mais simples a partir do conjunto 1 da figura 6.19, sem a estrutura 7. Essa imagem, com resolução de 64 x 64 pixels, é mostrada na figura 6.20.

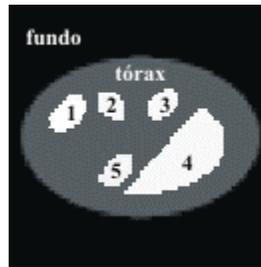


Figura 6.20. Imagem criada a partir do conjunto1 da Figura 6.19, sem a estrutura 5.

A partir da matriz apresentada na figura 6.20, foram criadas imagens com cinco níveis de contraste diferentes entre as estruturas internas e o tórax, pela variação da contagem nessa região, que são mostradas na figura 6.21.

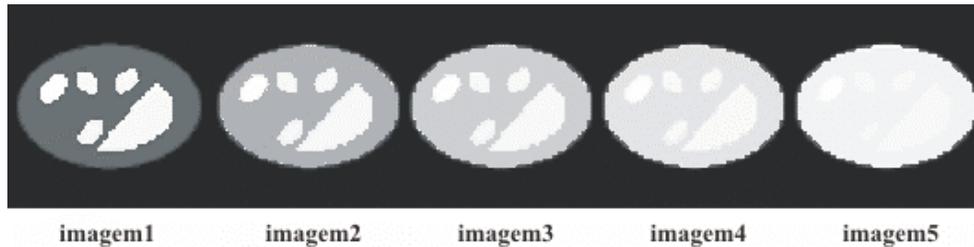


Figura 6.21. Imagens obtidas a partir da imagem apresentada na figura 6.20. Cada uma das imagens acima é obtida pela variação de contagem na região do tórax, que resulta na mudança de contraste das estruturas internas.

Para cada uma das imagens da figura 6.21, foram geradas imagens com três níveis diferentes de ruído gaussiano. Neste experimento, a estrutura a ser identificada é a estrutura 2. Assim, os valores de contraste e relação sinal-ruído serão considerados em relação a esta estrutura e o seu fundo – representado pelo tórax.

A tabela 6.5 apresenta os valores utilizados para calcular o contraste (equação 6.2.) e a relação sinal-ruído. Na tabela são apresentados os seguintes parâmetros:

μ_E = valor médio de intensidades do interior da estrutura 2;

μ_B = valor médio de intensidades do tórax;

σ_B = desvio padrão dos valores de intensidade do tórax;

$$C = \frac{|\mu_E - \mu_B|}{\mu_B} \quad (6.2)$$

contraste calculado entre a estrutura 2 e o tórax

Neste caso, o ruído é medido pela razão contraste-ruído, que é definida, em função das estruturas analisadas, como (Rangayan, 2004):

$$CNR = \frac{|\mu_E - \mu_B|}{\sigma_B} \quad (6.3)$$

CNR calculada entre a estrutura 2 e o tórax.

Tabela 6.5. Valores de razão contraste-ruído e contraste da estrutura 2 em relação ao tórax .

imagem original	tipo de ruído	μ_E	μ_B	C	σ_B	CNR
imagem1	baixo	250	2978	0,92	17	160
	médio	239	2971	0,92	117	23
	alto	375	2972	0,92	280	9
imagem2	baixo	250	2099	0,88	17	109
	médio	239	2092	0,88	117	16
	alto	375	2093	0,82	280	6
imagem3	baixo	250	1499	0,83	17	73
	médio	239	1492	0,83	117	11
	alto	375	1493	0,75	280	4
imagem4	baixo	250	999	0,75	17	44
	médio	239	992	0,76	117	6
	alto	375	993	0,62	280	2
imagem5	baixo	250	599	0,58	17	20
	médio	239	592	0,60	117	3
	alto	375	593	0,37	280	0,8

O método foi aplicado ao conjunto de imagens representadas pela tabela 6.5. Para criação do espaço de escalas e detecção dos GLBlobs utilizou-se $\tau = 0,19$.

Os resultados da construção do SSPS são apresentados nas figuras 6.22 a 6.24.

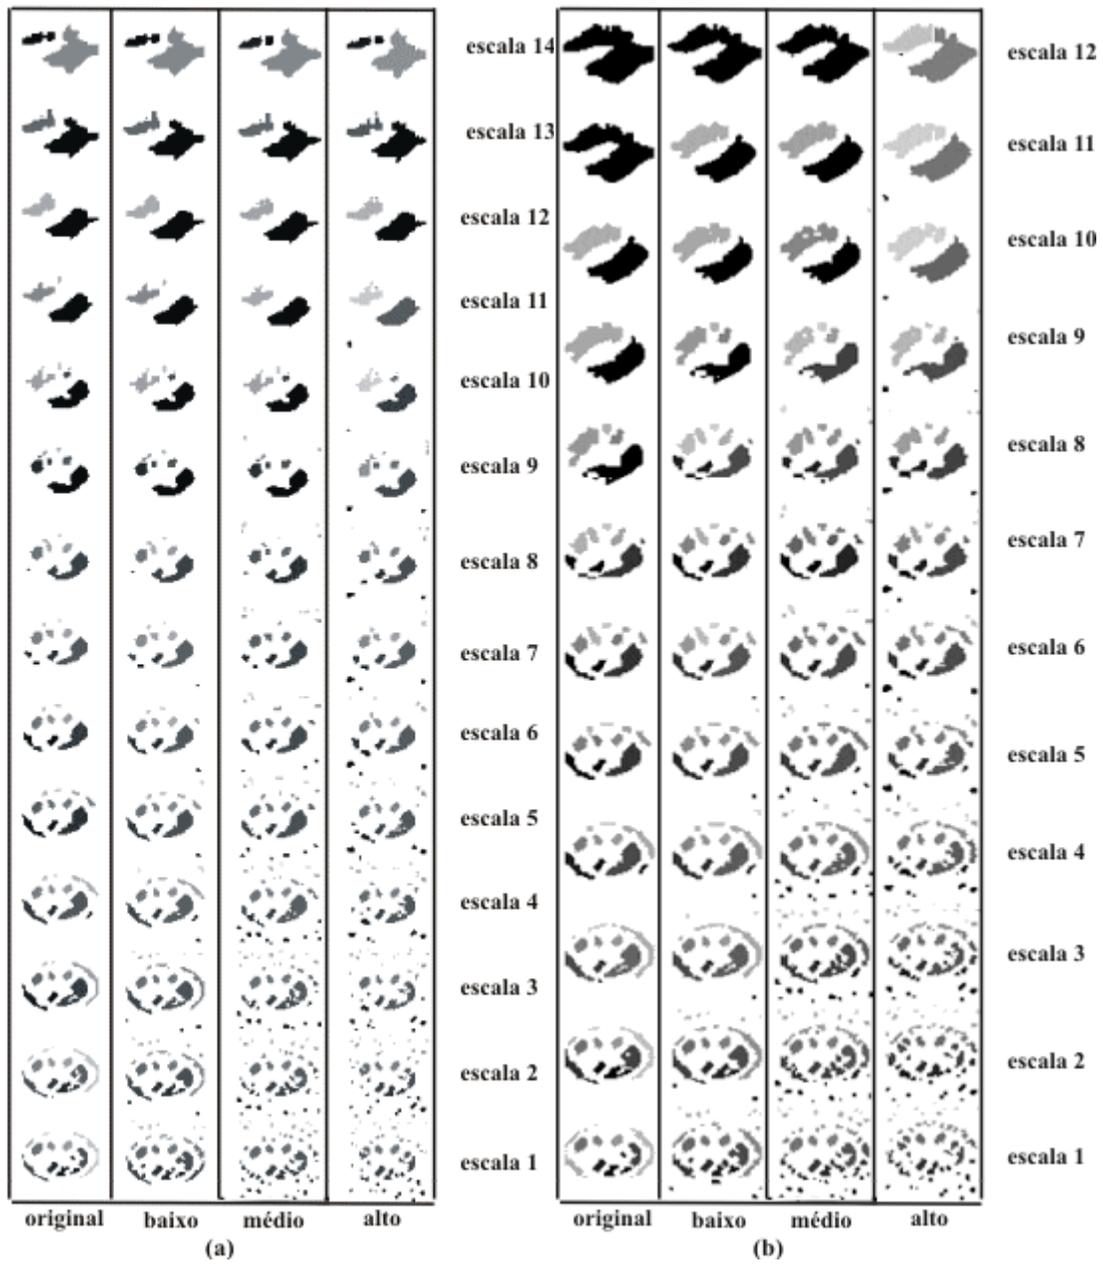


Figura 6.22. Blobs detectados nos espaços de escala das imagens (a) imagem1 e (b) imagem2, mostradas na figura 6.21, com $\tau = 0,19$. O conjunto apresentado em (b) contém um número menor de escalas porque as imagens das escalas superiores são idênticas à da escala 12.

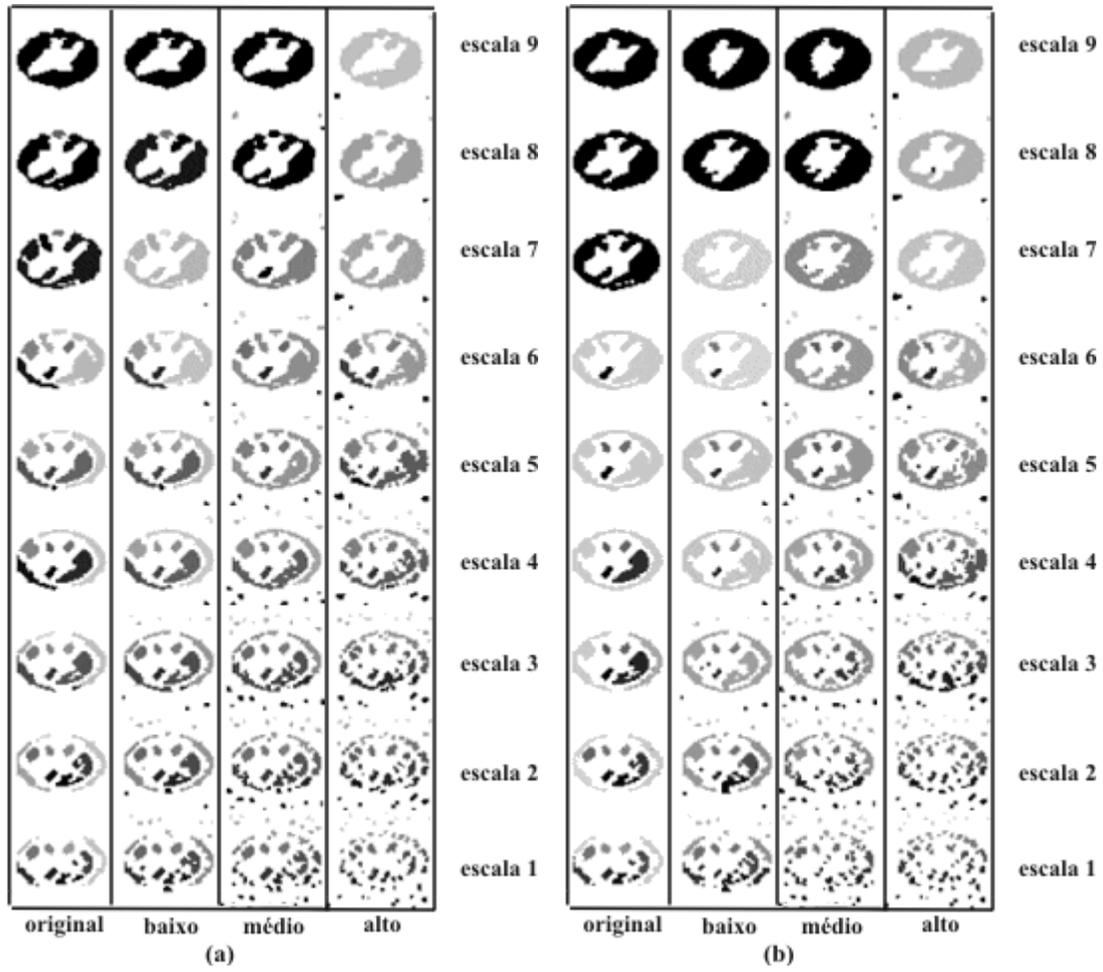


Figura 6.23. Blobs detectados nos espaços de escala das imagens (a) imagem3 e (b) imagem4, mostradas na figura 6.21, com $\tau = 0,19$.

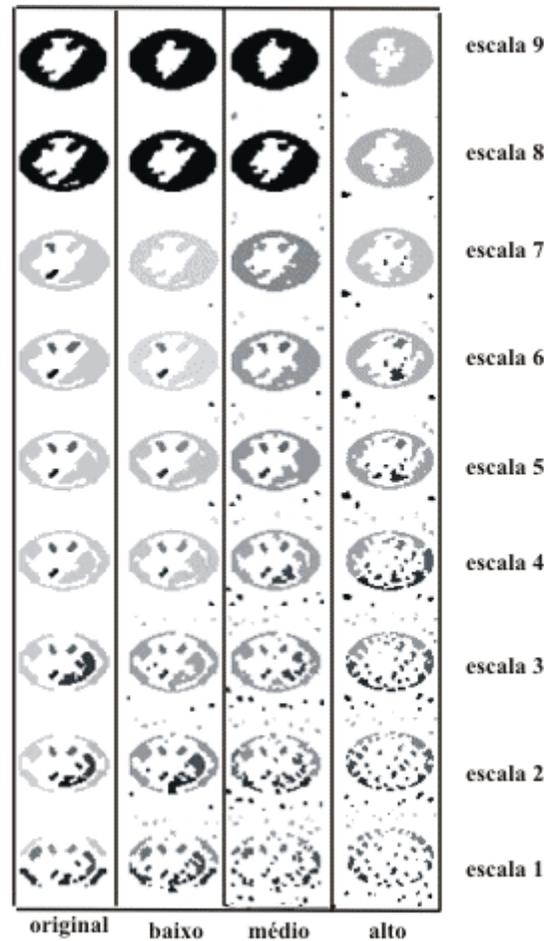


Figura 6.24. Blobs detectados nos espaços de escala da imagem5, mostradas na figura 6.21, com $\tau = 0,19$.

A observação mais importante a partir dos SSPS das imagens com contraste mais baixo entre as estruturas internas e o tórax (figuras 6.23.b e 6.24) é que o SSPS se mostra uma representação pouco eficiente para a identificação de estruturas. Devido ao baixo contraste entre o tórax e as estruturas internas, estas últimas se manifestam como SSBlobs únicos em poucos níveis do espaço de escalas. No caso extremo de baixíssimo contraste e alto ruído (figura 6.24 alto), a estrutura procurada não se manifesta em nenhum nível de escala. Pode-se verificar nessas imagens que o SSBlob que mais se destaca e que sobrevive por mais escalas é aquele que representa o tórax. Nas imagens com alto ruído, ele aparece apenas como uma coleção de pequenas estruturas na posição de borda e nas escalas muito baixas. Esses efeitos ocorrem porque ao mesmo tempo em que o contraste entre as

estruturas e o tórax diminuí, o contraste entre o tórax e o fundo da imagem aumenta, tornando a sua detecção pelo operador *umbilicity* mais eficiente.

Os valores de contraste e CNR, calculados para a estrutura 2 em relação ao tórax e para o tórax em relação ao fundo são apresentados na figura 6.25. Pode-se observar nos gráficos dessa figura que as imagens nas quais a estrutura interna sobrevive em um número maior de níveis de escala são aquelas nas quais o contraste entre a estrutura e o tórax é alto e o contraste entre o tórax e o fundo é baixo (imagens 1 e 2). À medida em que o primeiro valor de contraste diminui e o segundo aumenta, a estrutura que passa a ser predominante – o SSBlob que a representa sobrevive em um maior número de escalas – é o tórax (imagens 3, 4 e 5).

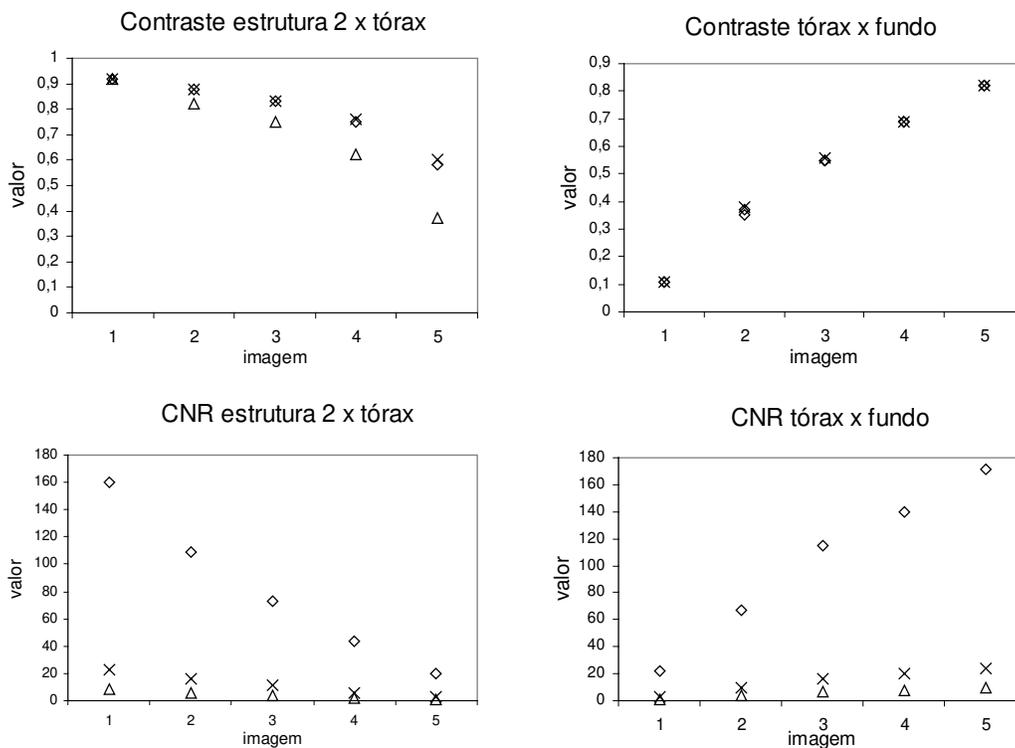


Figura 6.25. Valores de contraste e CNR calculados para as imagens da figura 6.21. À esquerda são apresentados os valores calculados para a estrutura 2 em relação ao tórax e à direita, para o tórax em relação ao fundo. As imagens com ruído baixo são indicadas por \diamond , as imagens com ruído médio por X, e as imagens com ruído alto por Δ .

Em princípio, todos os conjuntos de imagens devem ser comparados a um único padrão. Entretanto, neste experimento, essa comparação não é possível, pois devido à variação simultânea dos valores de contraste, os SSBlobs detectados são muito distintos entre os conjuntos. Foram criados padrões para cada conjunto de imagens, a partir da imagem original sem ruído, para verificar a aplicabilidade do método em conjuntos de imagens com diferentes condições de contraste.

Na tabela 6.6, apresentam-se os resultados obtidos para identificação das estruturas. O tempo de processamento para a obtenção dos resultados variou de 21 ms (imagem4 baixo ruído) até 16 s (imagem3 alto ruído).

Tabela 6.6. Resultados da etapa final de identificação da estrutura 2 nas imagens com diferentes níveis de contraste e ruído. \checkmark indica resultado correto na identificação e X representa resultado incorreto e ϕ indica sem resultado.

imagem	ruído baixo		ruído médio		ruído alto	
	$\pm 20\%$	$\pm 50\%$	$\pm 20\%$	$\pm 50\%$	$\pm 20\%$	$\pm 50\%$
imagem1	\checkmark	\checkmark	\checkmark	\checkmark	\checkmark	\checkmark
imagem2	ϕ	\checkmark	\checkmark	\checkmark	\checkmark	\checkmark
imagem3	\checkmark	\checkmark	\checkmark	\checkmark	X	\checkmark
imagem4	X	\checkmark	\checkmark	\checkmark	X	X
imagem5	\checkmark	\checkmark	X	\checkmark		

O método proposto identificou corretamente a estrutura procurada em 22 dos 28 experimentos. O índice de resultados corretos foi de 60% para a faixa de $\pm 20\%$. Esse índice foi elevado a 87% pela utilização da faixa de $\pm 50\%$. Na imagem 5 com alto ruído não foi possível aplicar o método pois, como já foi citado anteriormente, a estrutura 2 não se manifesta em nenhum nível de escala. Para a imagem 2 com ruído baixo e faixa de $\pm 20\%$, não foi obtido nenhum resultado porque todos os nós foram excluídos na etapa de simplificação da árvore.

Verificou-se que os blobs determinados corretamente com a faixa mais estreita do valor de volume de SSBlob, utilizada na redução das árvores, continuam sendo corretamente detectados com a faixa mais larga. Em alguns casos nos quais a identificação do blob tinha sido incorreta com a faixa mais estreita, o alargamento levou a uma resposta correta. Nesses

casos, o SSBlob que corresponde à estrutura 2 não havia sido classificado como candidato na primeira etapa do processamento. Esse resultado mostra a importância da escolha da faixa de variação do parâmetro discriminador na etapa de redução da árvore, que pode levar a resultados inconsistentes.

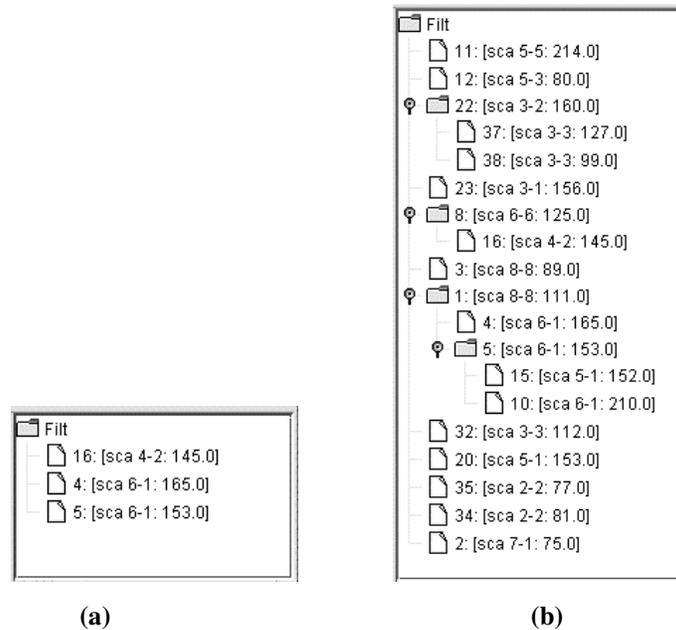


Figura 6.26. Redução da árvore de SSBlobs da figura 4 ruído médio. Em (a), a redução foi feita com a similaridade em relação ao padrão do parâmetro volume de SSBlob em $\pm 20\%$. Em (b), a faixa de similaridade foi aumentada para $\pm 50\%$.

A utilização de uma faixa mais larga de volume na primeira etapa faz com que o número de SSBlobs que participarão da etapa de casamento, utilizando ângulos e distâncias, seja maior, aumentando, conseqüentemente, o tempo de processamento. Na figura 6.26, apresentam-se as árvores obtidas para a imagem 4 com nível de ruído médio, utilizando-se $\pm 20\%$ (a) e $\pm 50\%$ (b) de variação permitida em relação ao volume do SSBlob padrão para determinação dos blobs candidatos. A utilização das duas faixas identificou corretamente a estrutura, porém o tempo de processamento aumentou de 62 ms, para a faixa de $\pm 20\%$, para 469 ms, para a faixa de $\pm 50\%$.

No experimento apresentado, a variação do contraste entre a estrutura de interesse e o fundo foi obtida pela modificação dos valores de intensidade do tórax na imagem 6.20. O

objetivo dessa modificação era observar o comportamento do método em diferentes condições de contraste. No entanto, a modificação dos valores de contraste realizada desta forma introduziu uma nova variável ao problema, o contraste entre o tórax e o fundo, o que dificulta a análise do problema colocado. A utilização desse conjunto de imagens permitiu a observação de uma limitação do método proposto: em imagens com baixo contraste entre a estrutura procurada e sua vizinhança e com alto contraste entre essa vizinhança e o fundo, o método não é eficiente. Embora ele seja capaz de identificar a estrutura procurada, é necessário realizar muito esforço de processamento em um espaço de escalas no qual a estrutura de interesse é pouco significativa.

Para isolar o parâmetro desejado, ou seja, o contraste entre a estrutura 2 e o tórax, foi criado um novo conjunto de imagens, a partir da manipulação da imagem apresentada na figura 6.20. Neste caso, foram modificados os valores de intensidade da região do tórax – com objetivo de diminuir o contraste entre ele e a estrutura 2 – e também os valores de intensidade do fundo – de forma a manter constante o contraste entre o tórax e o fundo. A figura 6.27 apresenta as cinco imagens utilizadas no próximo experimento.

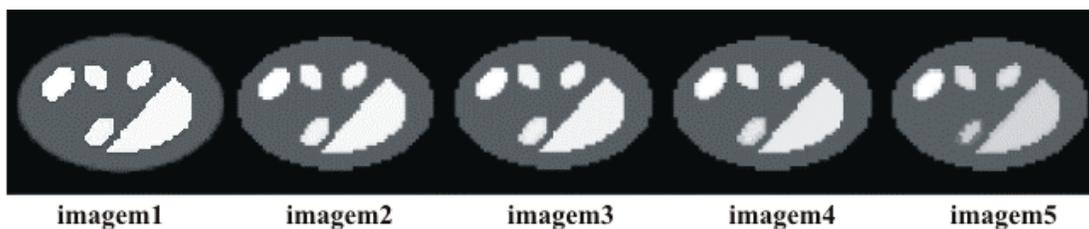


Figura 6.27. Imagens obtidas a partir da imagem apresentada na figura 6.20. Cada uma das imagens acima é obtida pela variação de contagem na região do tórax e na região de fundo, que causam a mudança de contraste dos órgãos internos e a mudança de contraste tórax-fundo.

Na figura 6.28 apresentam-se os gráficos com valores de contraste e CNR, calculados para a estrutura 4 em relação ao tórax e para o tórax em relação ao fundo, para as imagens apresentadas na figura 6.27.

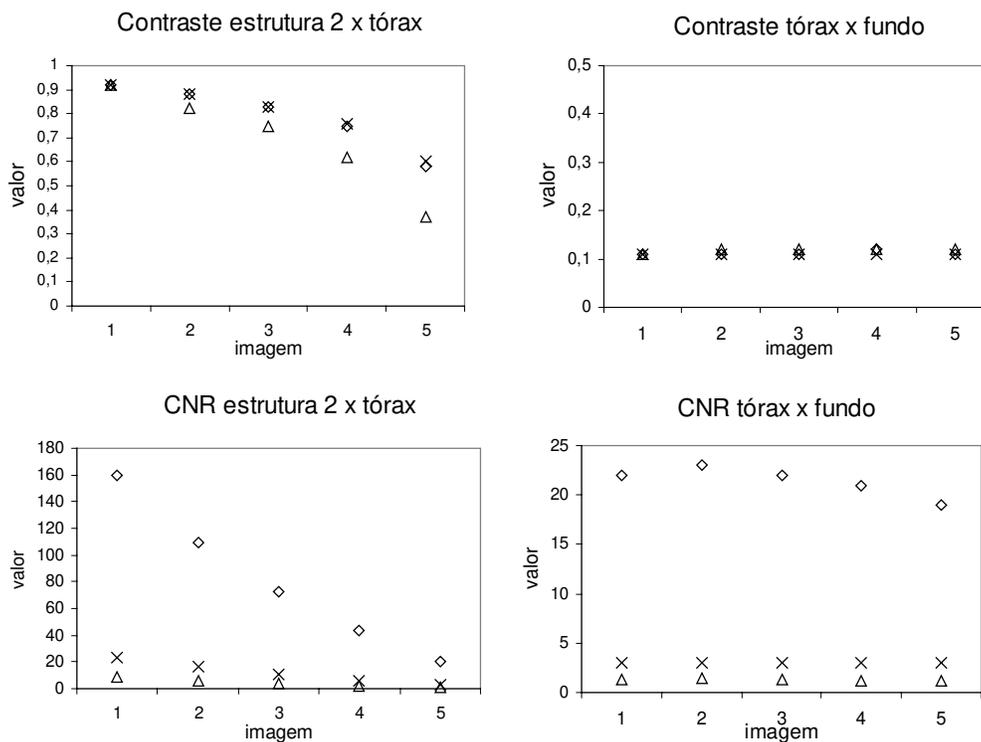


Figura 6.28. Valores de contraste e CNR calculados para as imagens da figura 6.27. As imagens com ruído baixo são indicadas por \diamond , as imagens com ruído médio por \times , e as imagens com ruído alto por Δ .

Os resultados da construção do SSPS – utilizando $\tau = 0,19$ - para o novo conjunto de imagens são apresentados nas figuras 6.29 a 6.31.

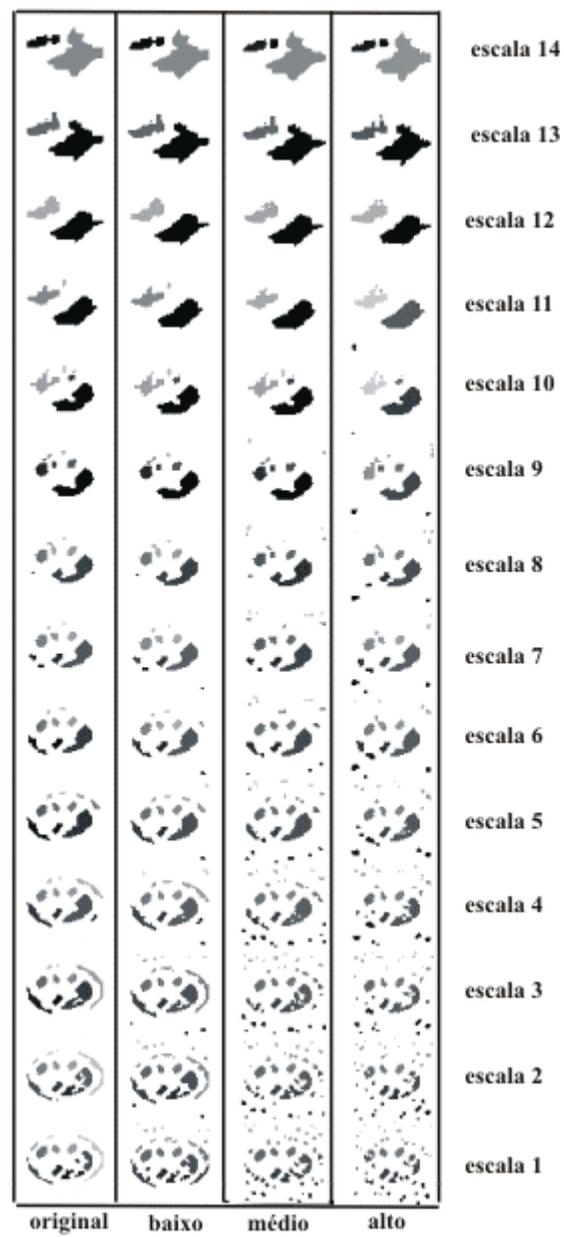


Figura 6.29. Blobs detectados nos espaços de escala da imagem1 mostrada na figura 6.26, com $\tau = 0,19$.

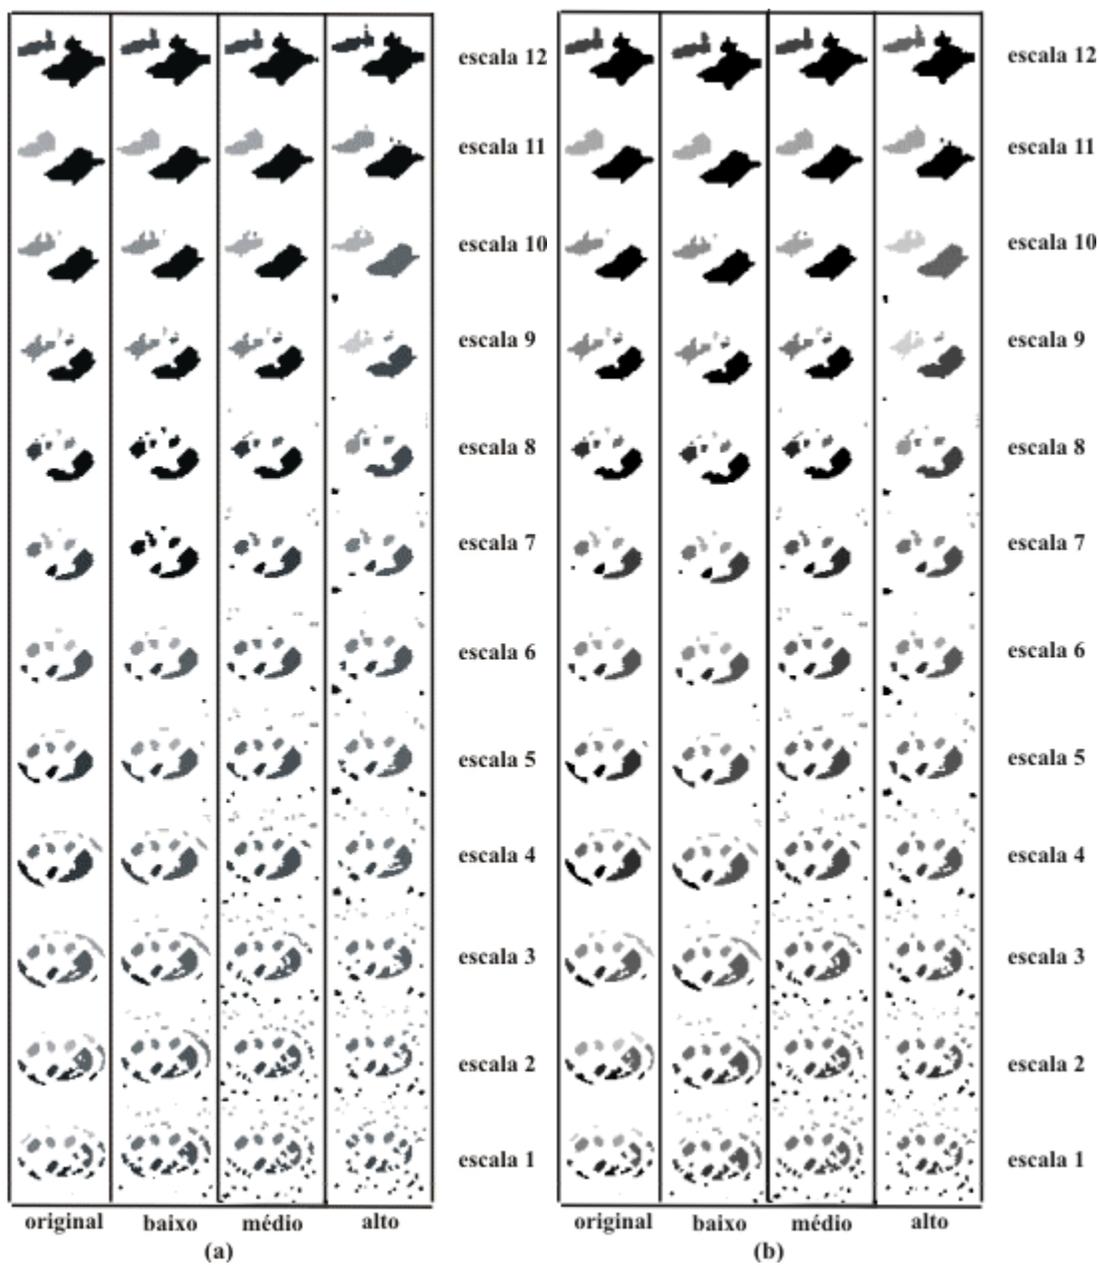


Figura 6.30. Blobs detectados nos espaços de escala das imagens imagem2 (a) e imagem3 (b), mostradas na figura 6.26, com $\tau = 0,19$.

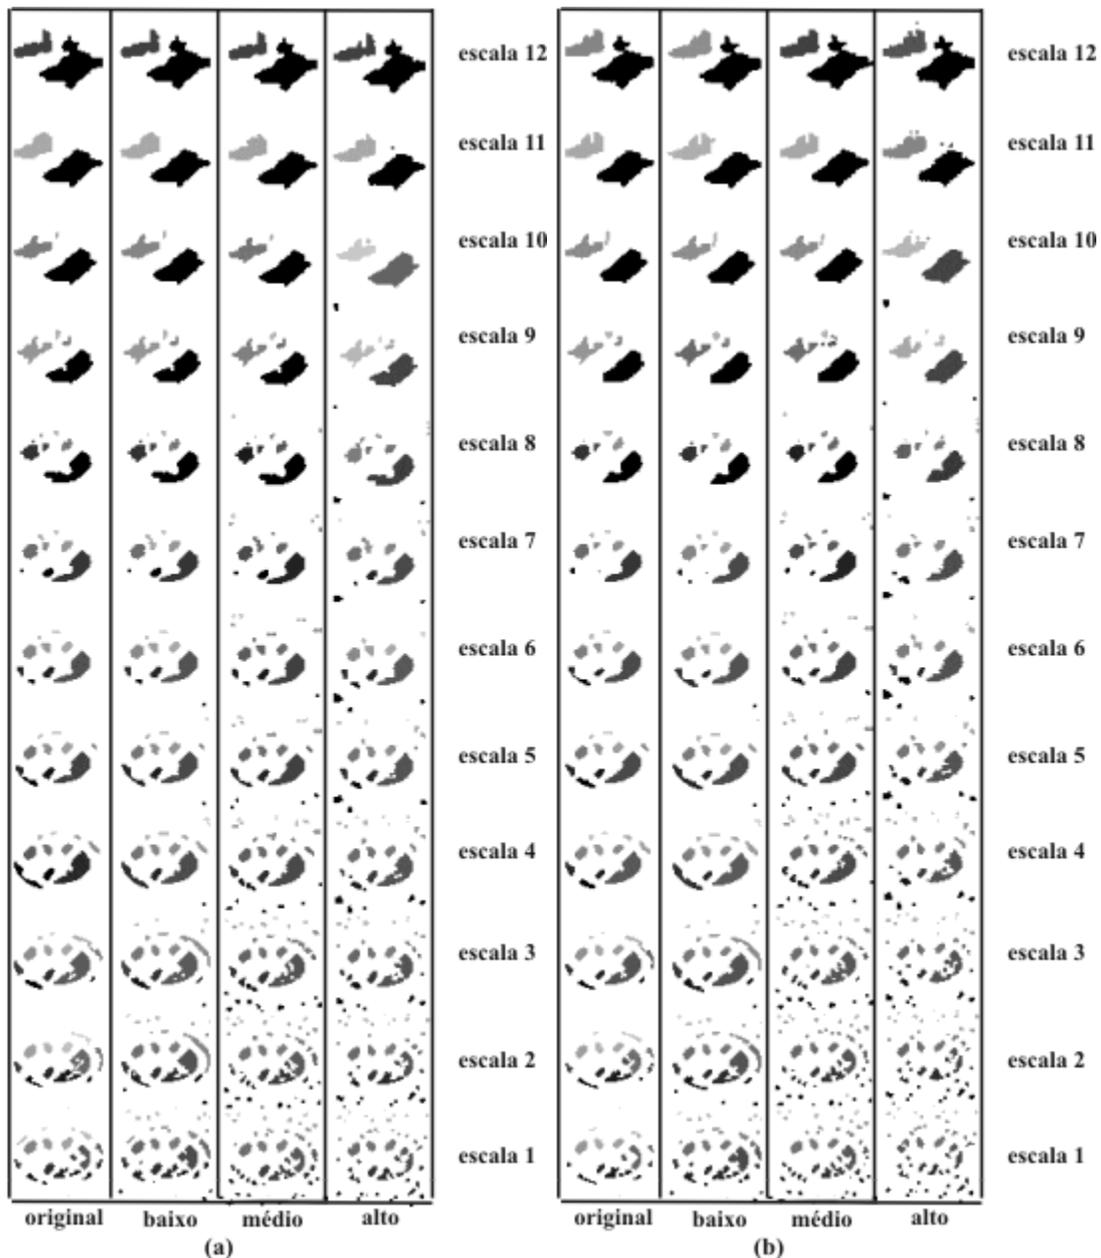


Figura 6.31. Blobs detectados nos espaços de escala das imagens imagem4 (a) e imagem5 (b), mostradas na figura 6.26, com $\tau = 0,19$.

As figuras 6.30 e 6.31 mostram que quando a relação de contraste entre o tórax e o fundo é mantida, os blobs das imagens com contraste baixo entre as estruturas internas e o tórax passam a ter um comportamento próximo àquele observado nas imagens com alto contraste, apresentado na figura 6.27. Todas as estruturas internas sobrevivem em um número menor de níveis de escala à medida em que o contraste entre elas e o tórax diminui.

A estrutura 5, por exemplo, sobrevive até o nível de escala 8 no conjunto da imagem 1 (figura 6.29), nos conjuntos das imagens [2,3,4] ela sobrevive até a escala 7 e no conjunto da imagem5, sobrevive apenas até a escala 6.

Para identificação da estrutura 2, foi utilizado primeiramente o padrão estabelecido para o conjunto da imagem 1, com o maior contraste. A utilização do padrão desse conjunto de imagens permitiu apenas a identificação da estrutura no conjunto da imagem 2. Isso ocorreu devido à forma como o padrão é estabelecido, isto é, determinando a escala mais significativa como a escala mais alta na qual aparecem todas as estruturas que representam objetos reais da imagem. Entretanto, a escala mais adequada para uma estrutura presente em uma imagem com alto contraste pode não conter essa estrutura em imagens com contrastes mais baixos, pois as razões para a forma da escolha da escala mais adequada, apresentadas no item 5.2.2, não consideram a influência do contraste na geração do espaço de escalas. Os experimentos realizados mostraram que a influência do contraste deve ser considerada na geração do padrão. Existem diversas formas de inserir essa dependência. Uma delas é avaliar imagens com diferentes contrastes entre as estruturas e determinar para esse conjunto qual é a escala adequada mínima. Com essa escolha, seria garantido que, em imagens com contraste mais alto, as estruturas existiriam na escala para comparação. Para a identificação da estrutura 2 no presente experimento, foi utilizado o padrão determinado para o conjunto da imagem5, a partir de sua imagem original sem ruído.

Os resultados da identificação da estrutura 4 são apresentados na tabela 6.7.

Tabela 6.7. Resultados da etapa final de identificação da estrutura 2 nas imagens com diferentes níveis de contraste e ruído. \checkmark indica resultado correto na identificação e X representa resultado incorreto e ϕ indica sem resultado.

imagem	ruído baixo		ruído médio		ruído alto	
	$\pm 20\%$	$\pm 50\%$	$\pm 20\%$	$\pm 50\%$	$\pm 20\%$	$\pm 50\%$
imagem1	\checkmark	\checkmark	\checkmark	\checkmark	ϕ	X
imagem2	\checkmark	\checkmark	\checkmark	\checkmark	ϕ	\checkmark
imagem3	\checkmark	\checkmark	ϕ	\checkmark	\checkmark	\checkmark
imagem4	\checkmark	\checkmark	ϕ	\checkmark	ϕ	X
imagem5	\checkmark	\checkmark	\checkmark	\checkmark	X	\checkmark

Os resultados da tabela 6.9 mostram que neste caso a utilização da faixa permitida de variação do volume de SSBlob de $\pm 20\%$ não produziu resultados em várias imagens, evidenciando a variação maior entre as imagens testadas no experimento. Em uma aplicação em imagens médicas reais, o comportamento deve ser semelhante, ou seja, a variabilidade é grande. No caso de imagens reais o padrão pode ser obtido a partir de um conjunto de amostras e a escala mais adequada também deve ser escolhida como a mais baixa entre as determinadas para cada imagem individualmente. A utilização da faixa de $\pm 50\%$ levou ao resultado correto em 87% dos experimentos.

The important thing in science is not so much to obtain new facts as to discover new ways of thinking about them.

- Sir William Bragg

Capítulo 7

Conclusão

7.1. Considerações finais

A visualização e a análise quantitativa de órgãos e sistemas são objetivos amplamente perseguidos em processamento de imagens e visão computacional aplicados à área médica. Essas operações implicam no isolamento preciso do órgão ou sistema sob análise. Essa é uma tarefa difícil, devido à complexidade das estruturas envolvidas. Uma forma de atingir esses objetivos é dividir a tarefa em duas fases. Primeiro, identifica-se a estrutura procurada em meio ao conjunto de outras estruturas presentes na cena. Nessa fase, a qualidade da segmentação não precisa ser excelente. Então, em uma segunda fase, os resultados obtidos na fase anterior podem ser utilizados para um procedimento de refinamento da segmentação.

Este trabalho pretendeu contribuir na busca de uma solução mais genérica para a primeira fase desse processo. Nele, foi apresentado um método para identificação de estruturas em imagens, que utiliza conceitos de detecção de características das imagens em múltiplas escalas e inserção de informações *a priori* para realizar a tarefa desejada.

A proposta metodológica é dividida em três fases, cada uma das quais corresponde a um dos três níveis de processamento de imagens normalmente descritos na literatura: baixo, médio e alto. Na fase de processamento de baixo nível, é construída uma representação dos dados em diversas escalas, utilizando a teoria de espaço de escalas linear. No nível

intermediário de processamento, as imagens presentes em todas as escalas são analisadas, com a extração de parâmetros e a construção da representação *SSPS*. O resultado dessa fase é usado como entrada para um método de processamento de alto nível, no qual se embute o conhecimento obtido nas fases anteriores, além de conhecimento anatômico e contextual, para a identificação das estruturas procuradas.

A abordagem utilizando espaço de escalas foi escolhida para o processamento de baixo nível por várias razões, dentre as quais pode-se citar: é uma forma de processamento básica, que pode ser utilizada para um número muito grande de aplicações; reduz o nível de ruído, requisito necessário em qualquer sistema de processamento de imagens médicas; permite que o processamento seja feito no nível de escala mais apropriado ao detalhe da imagem que se deseja analisar, e permite relacionar estruturas em diferentes níveis de resolução. Além disso, a utilização com sucesso da abordagem de espaço de escalas para o cálculo de operadores diferenciais em imagens médicas em trabalhos para determinação do movimento de paredes cardíacas, mostrou a aplicabilidade da teoria em situações distintas.

Um dos principais objetivos deste trabalho foi pesquisar uma representação para descrever adequadamente as imagens, de forma a facilitar a etapa de alto nível para identificação. A análise das características da representação de *Scale Space Primal Sketch*, descrita originalmente para imagens naturais, indicava que elas eram adequadas para a representação pretendida e que a representação poderia ser utilizada com sucesso em imagens médicas. Essa possibilidade foi avaliada no teste realizado com imagens de ressonância magnética, apresentado no capítulo 4. Os resultados obtidos mostraram a adequabilidade da representação a imagens médicas, com a extração das estruturas relevantes da imagem pela utilização de um parâmetro de significância genérico, o mesmo utilizado para as imagens naturais.

A implementação do *Scale Space Primal Sketch* feita neste trabalho não utilizou o operador morfológico *watershed* para detecção dos GLBlobs, como na proposição original do método encontrado na literatura. Desejava-se utilizar um operador de imagem mais formal, que permitisse um estudo teórico dos eventos envolvidos na criação do *SSPS*. Tal estudo levou a uma formulação para a determinação da escala mais adequada para o

processamento da imagem. O operador *umbilicity* se mostrou bastante adequado, tanto na detecção de estruturas na imagem como no seu equacionamento ao longo das escalas, conforme é apresentado no apêndice II. As análises quantitativa e qualitativa dos resultados experimentais, obtidos pelas simulações no apêndice e pelo *phantom* nos capítulos 5 e 6, corroboram a escolha. Entretanto, a análise teórica realizada ainda não é suficiente para a determinação das escalas de sobrevivência em condições reais, pois ela não leva em consideração os fatores ruído e erros de precisão nos cálculos e valores dos dados de intensidade das imagens. Além disso, a questão da presença de outras estruturas foi abordada apenas no caso do operador limiar, e para uma situação bastante particular de duas estruturas de mesma dimensão a uma distância igual ao tamanho das estruturas. Esse resultado deve ser estendido para estruturas de tamanhos distintos a uma distância arbitrária. Os mesmos passos devem ser seguidos para a abordagem utilizando o operador *umbilicity*.

O próximo passo, para a finalização do método, foi a inclusão de informações *a priori* na representação. Este trabalho analisou não apenas a utilização de informação sobre a estrutura desejada, mas também a inclusão de conhecimento sobre o contexto da cena, como a posição relativa entre as estruturas, na tarefa de identificação. O tipo de informação a ser embutido na representação depende de alguns fatores, como modalidade da imagem e estrutura a ser identificada, ou ainda, grau de normalidade da estrutura a ser identificada. Foi então implementado um protótipo, que insere no método proposto a etapa de alto nível, pela implementação de uma rotina para casamento de padrões. Os experimentos descritos no capítulo 6 tiveram o objetivo de analisar o método sob condições controladas. Para avaliação e testes, foi adotado um *phantom* matemático utilizado pela comunidade de Medicina Nuclear, o *phantom* MCAT.

Nos experimentos realizados, o padrão foi obtido a partir da imagem do *phantom* original, sem a presença de ruído. O método proposto permite, ainda, a criação de padrões a partir da aplicação em um conjunto de casos em uma base de imagens. Essa característica torna o método bastante interessante para aplicações médicas, pois permite que sejam criados diferentes padrões para um mesmo órgão com diferentes condições anatômicas e

funcionais. Ele possibilita, também, que esse conhecimento se amplie, à medida que novos casos sejam acrescentados.

No protótipo implementado, utilizou-se o volume de SSBlob como um dos parâmetros utilizados para o casamento de padrões. Segundo a literatura, o tamanho da estrutura não é, em princípio, um bom parâmetro discriminador para sistemas automáticos para extração em imagens médicas, pois dependendo da estrutura estudada, mesmo para indivíduos normais, pode haver uma faixa de variação muito grande nos seus valores. Essa afirmação, entretanto, é válida para comparações realizadas em uma única escala e utilizando outras formas de representação. Os resultados obtidos na extração de SSBlobs significativos da imagem de ressonância magnética mostraram que esse parâmetro pode indicar, em uma primeira aproximação, se o SSBlob é significativo em uma imagem ou não, ou, em outras palavras, se ele representa uma estrutura “real” da imagem. Esses resultados forneceram a indicação que ele poderia ser um parâmetro utilizado para a redução da busca na etapa de casamento, que, de outra forma, se tornaria inviável computacionalmente. Essa análise levou à descrição de duas etapas de casamento de padrões. A análise da utilização do parâmetro volume do SSBlob não foi conclusiva. Nos experimentos realizados neste trabalho, não foi possível determinar a faixa ideal de variação do volume do SSBlob para redução da árvore. Nos experimentos realizados foram consideradas duas faixas: $\pm 20\%$ e $\pm 50\%$. A utilização da primeira permitiu a identificação na maioria dos casos, entretanto, levou a resultados incorretos algumas vezes, pois os nós que representavam a estrutura real eram eliminados na primeira fase. A utilização de faixas muito largas de variação permitida deve ser evitada, pois leva a um tempo maior de processamento e, no limite, inutiliza essa etapa. A necessidade de se adotar uma faixa muito larga significa que o parâmetro escolhido não é adequado na discriminação da estrutura procurada.

Outra etapa importante do método é o uso do conceito de escala mais adequada para processamento. Ele permite a diminuição do espaço de buscas na etapa de casamento de padrões, reduzindo o tempo de processamento, que é realizado em uma escala em que as estruturas reais da imagem são destacadas. A escolha dessa escala deve considerar o

tamanho das estruturas presentes na imagem e também o operador utilizado para sua detecção.

Os atributos distâncias e ângulos na escala mais adequada se mostraram bastante eficazes na identificação. Porém, a sua utilização na primeira etapa do casamento de padrões seria pouco eficiente. Os resultados mostraram a eficiência da redução de árvore: a utilização de um parâmetro discriminante, ainda que de modo genérico, das estruturas procuradas e cujo cálculo não seja custoso a partir da estrutura de dados do SSBlob, retira da busca mais fins que representariam estruturas totalmente discrepantes em relação àquela procurada, eliminando cálculos inúteis. A segunda redução, pela determinação da escala mais adequada, permite focar o processamento em um único nível de escala.

O método se mostrou sensível em imagens com ruído muito alto, da ordem de 8 dB, para as quais pode fornecer resultados incorretos. Um nível tão alto de ruído ocorre em uma imagem cuja intensidade média do sinal corresponde a apenas 2,5 vezes a intensidade média do ruído. Tais níveis de ruído não são comuns em imagens médicas. Eles só ocorrem, excepcionalmente, em condições particulares em imagens de Medicina Nuclear e Ultra-som.

Os experimentos realizados com imagens com diferentes níveis de contraste indicaram uma limitação do método, que se mostrou ineficiente para identificação de estruturas com baixo contraste em relação à sua vizinhança, quando essa região de vizinhança apresenta alto contraste em relação ao fundo da imagem. Por outro lado, o experimento com imagens nas quais o contraste entre o tórax e o fundo foi mantido constante, evidenciou a necessidade de se inserir o fator de influência do contraste na construção do SSPS para a determinação da escala mais adequada. Imagens com uma mesma geometria, porém com contrastes diferentes entre as estruturas internas do *phantom*, apresentaram SSPS com o mesmo comportamento, porém com faixas de sobrevivência menores no caso de contraste mais baixo. Como a segunda etapa de casamento de estruturas é realizada na escala de sobrevivência mais alta, é essencial que ela englobe as estruturas de interesse em diferentes níveis de contraste. Assim, o padrão determinado a partir de um conjunto de imagens deve utilizar a escala de interesse mais baixa determinada para o conjunto de imagens com diferentes contrastes.

A análise de imagens em diferentes resoluções sugere que o comportamento das estruturas, em termos de escalas de aparecimento e desaparecimento, tende a seguir um padrão. O experimento realizado neste trabalho não foi conclusivo e necessita de pesquisa mais aprofundada para que se obtenha uma relação, ou talvez um padrão de comportamento, que possa definir uma assinatura em espaço de escalas para a imagem.

7.2. Contribuições do trabalho

Método para identificação automática de estruturas em imagens médicas

O trabalho apresenta uma proposta para identificação de objetos, utilizando uma estrutura de imagens que embute o conceito de múltiplas escalas e que permite incluir, naturalmente, as informações de dimensão dos objetos procurados na imagem. A proposta é baseada na premissa de que um sistema de identificação de imagens deve conter informações sobre o objeto procurado. O método descrito é genérico, no sentido de que ele é independente da modalidade da imagem e da estrutura anatômica procurada. A especificidade da busca é definida pelos parâmetros utilizados para descrever a estrutura, que são facilmente inseridos na estrutura de dados criada.

Inclusão de informações *a priori*

A inclusão de informações *a priori* é adotada em vários trabalhos da literatura. Neste trabalho, enfatiza-se a utilização de informações não apenas da própria estrutura, mas também informações contextuais da imagem, que são largamente consideradas por seres humanos na identificação de objetos. Foi avaliada, especificamente, a informação de posição relativa dos órgãos, descrita em termos de distâncias e ângulos.

Redução do espaço de busca

O método é viabilizado pela redução do espaço de busca na etapa de casamento de padrões, pela redução da árvore de SSBlobs e pela determinação da escala mais adequada de processamento. A escolha dessa escala leva em consideração fatores distintos daqueles que normalmente são citados na literatura de espaço de escalas. Para fins de identificação, o

fator mais importante no método proposto é a presença de todas as estruturas “reais” na cena, enfatizando o contexto da estrutura procurada para sua caracterização.

Possibilidade de treinamento com bases de dados

O software para estabelecimento do padrão permite que este seja criado a partir de uma imagem sintética, como foi feito nos experimentos apresentados no texto, ou a partir de um conjunto de imagens reais. Essa característica pode ser considerada para realizar o treinamento a partir de bases de dados de imagens médicas, o que amplia suas possibilidades de uso clínico. Grupos de diferentes patologias de um mesmo órgão ou sistema podem produzir padrões distintos, que permitam distingui-las em uma imagem teste.

Equacionamento teórico da escala mais significativa

Este trabalho apresentou um equacionamento para a determinação da faixa de escalas de sobrevivência de estruturas com tamanhos conhecidos, a partir de dois operadores de imagem. Os resultados obtidos aqui indicam que, com o conhecimento do tamanho das estruturas presentes na imagem e a expressão do operador utilizado, pode-se determinar a faixa de escalas de sobrevivência da estrutura. Com essa informação, a escala mais adequada para processamento pode ser determinada. Essa informação pode auxiliar não apenas na identificação, mas também em outras tarefas de processamento, como segmentação e fusão de objetos.

7.3. Trabalhos futuros

Utilização em imagens médicas para verificação da aplicabilidade clínica: avaliação de parâmetros para imagens de modalidades diferentes em 2D e 3D

Uma extensão importante deste trabalho é a avaliação da aplicabilidade clínica do método. Devem ser escolhidas algumas aplicações piloto de diferentes modalidades e com diferentes órgãos. Dessa análise, deverão surgir algumas situações para as quais a aplicação do método seja mais adequada. As etapas de criação do espaço de escalas, detecção de GLBlobs e criação da árvore de SSPS já estão implementadas para 2D e 3D. Para aplicação

em imagens tridimensionais, o principal desafio será determinar o conjunto de parâmetros adequado para caracterização dos órgãos.

Avaliação mais detalhada do parâmetro volume de SSBlob na etapa de simplificação da árvore

A utilização do parâmetro volume para redução da árvore de SSBlobs em imagens médicas precisa ser melhor estudada, para que se possa avaliar em que nível a variação da estrutura entre indivíduos normais ultrapassa a variação entre ela e outras estruturas presentes. A análise da adequabilidade da utilização de um parâmetro que reflita o tamanho da estrutura deve ser realizada em um trabalho com um conjunto suficientemente representativo de imagens clínicas, e que englobe diferentes órgãos, para que se possa chegar a uma conclusão definitiva. Uma possibilidade a ser estudada é a utilização desse parâmetro em um conjunto de imagens no qual o volume permita discriminar a normalidade de órgãos baseada em variação de seu valor.

Utilização do método como parte de um sistema de recuperação de imagens por conteúdo

Uma aplicação clínica a ser pesquisada para o método proposto é a sua utilização como parte de um sistema de buscas por conteúdo em imagens (CBIR), na qual a fase de redução discriminaria o órgão e na fase mais fina de casamento de padrões, parâmetros mais específicos poderiam ser utilizados para identificar patologias.

Avaliação mais detalhada da possibilidade de generalizar as faixas de sobrevivência em imagens em diferentes resoluções originais

A análise de imagens com estruturas geométricas idênticas em imagens com resolução original diferentes será feita a partir de imagens de Medicina Nuclear, utilizando *phantom* físico, com aquisições em resoluções diferentes. Pretende-se avaliar mais detalhadamente a possibilidade de criar uma *assinatura* em termos de árvores de espaços de escala.

Extensão da análise teórica para inclusão da influência de outros fatores na determinação da faixa de escalas de sobrevivência

A formulação para determinação da faixa de escalas de sobrevivência das estruturas deve ser estendida para incluir as informações de ruído, erros de precisão nos cálculos e valores de intensidade nas imagens e também a presença de outras estruturas próximas, para caso do operador *umbilicity*. Para o caso do operador limiar, para o qual já foi feita uma análise em uma situação particular de presença de outra estrutura, essa análise deve ser generalizada para estruturas de qualquer dimensão e a distâncias genéricas.

Utilização de espaços de escala não lineares para segmentação mais fina após a identificação

Uma segmentação mais acurada da estrutura desejada pode ser feita após a sua identificação na imagem. A informação sobre a localização e a forma das regiões de interesse e de suas bordas, obtida pela aplicação do método proposto, pode ser colocada na formulação da equação de difusão não-linear. Por outro lado, a informação sobre a escolha da faixa de escalas mais adequada para descrever determinada região, também possível pela aplicação do método, pode ser utilizada como delimitadora da faixa de escalas para análise dessa região. Para tanto, deve-se efetuar um estudo de como relacionar o parâmetro de escalas determinado para o espaço de escalas linear e os parâmetros do espaço de escalas não linear.

Apêndice I

Tempos de Processamento

Tabela AI.1. Tempos de processamento dos resultados apresentados na figura 3.6.

número de níveis	64 x 64 - t(s)	128 x 128 - t(s)	256 x 256 - t(s)
1	< 1	0	0
2	< 1	1	1
3	< 1	1	2
4	1	2	3
5	1	2	4
6	1	3	5
7	1	4	6
8	2	5	8
9	2	6	9
10	2	8	11
11	3	10	14
12	3	11	16
13	4	14	20
14	4	17	24

Tabela AI.2. Tempos de processamento dos resultados apresentados na Figura 3.8.

número de níveis	t (s) Sun	t (s) Xeon
1	8	1
2	18	3
3	30	5
4	42	7
5	57	9
6	76	13
7	97	16
8	122	20
9	152	25
10	187	30
11	228	38
12	277	46
13	338	56
14	404	67

Tabela AI.3. Tempos de processamento dos resultados apresentados na Figura 4.11.

número de níveis	64 x 64 - t(s)	128 x 128 - t(s)	256 x 256 - t(s)
1	< 1	1	2
2	< 1	1	5
3	< 1	2	8
4	1	2	11
5	1	4	15
6	2	5	19
7	2	6	25
8	3	8	31
9	3	10	39
10	4	11	47
11	4	14	57
12	5	17	69
13	5	20	83
14	6	24	99

Tabela AI.4. Tempos de processamento dos resultados apresentados na Figura 4.12.

número de níveis	t (s) SUN	t (s) Xeon
1	13	2
2	31	5
3	50	8
4	71	12
5	93	15
6	124	21
7	157	26
8	197	33
9	243	41
10	295	49
11	357	60
12	433	72
13	524	87
14	629	105

Whenever anyone says, 'theoretically,' they really mean, 'not really'.

- Dave Parnas

Apêndice II

Escalas de sobrevivência de estruturas

Neste apêndice, será abordada a questão da determinação de escalas de sobrevivência de estruturas no espaço de escalas. Será investigada a detecção de estruturas utilizando dois operadores: o operador limiar e o operador *umbilicity*. Para o primeiro, será feita a análise de sobrevivência da estrutura no espaço de escalas em sinais unidimensionais, primeiramente para a estrutura isolada e depois, será avaliada a influência de outra estrutura próxima. Para o operador *umbilicity*, a análise será feita para uma estrutura isolada em imagens bidimensionais.

Caso 1. Detecção de estruturas em sinais 1D feita a partir de limiar

a. Caso da estrutura isolada

Dada uma função unidimensional $f(x)$, a convolução dessa função com a função gaussiana $g(x)$ é descrita por:

$$C(x) = f(x) \otimes g(x) = \int_{-\infty}^{\infty} f(t) \cdot g(t-x) dt$$

$$g(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{x^2}{2\sigma^2}} \tag{AII.1}$$

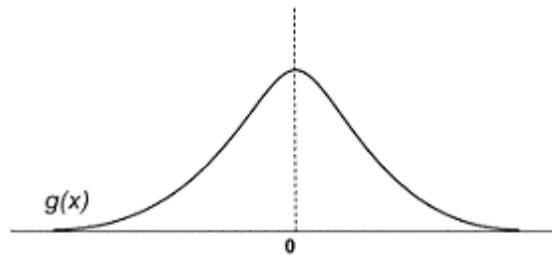


Figura AII.1. Função gaussiana unidimensional

Na teoria de espaços de escala, faz-se a convolução da função $f(x)$ com gaussianas com valores de σ crescentes. Assim, para o espaço de escalas, a operação de convolução é dada pela expressão AII.2:

$$C(x, \sigma) = f(x) \otimes g(x, \sigma) = \int_{-\infty}^{\infty} f(t) \cdot g(t - x, \sigma) dt \quad (\text{AII.2})$$

Deseja-se avaliar a possibilidade de determinar *a priori* os valores de σ para os quais é possível detectar de uma estrutura com extensão e amplitude conhecidas. O objetivo desta formulação é encontrar uma relação entre σ e os parâmetros que caracterizam a estrutura.

Supondo que o sinal $f(x)$ seja dado pela expressão (AII.3), a sua representação tem a forma mostrada na figura AII.2.

$$f(x) = \begin{cases} a & |x| \leq b/2 \\ 0 & \text{caso contrário} \end{cases} \quad (\text{AII.3})$$

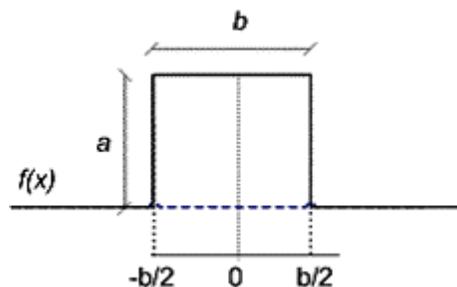


Figura AII.2. Sinal unidimensional de uma onda quadrada.

Para fins didáticos, será utilizada uma função simples de detecção de estruturas, o limiar. Para um dado limiar T , interessa saber a relação entre os valores de σ tais que a

aplicação da função de convolução (AII.2) permita a detecção do objeto caracterizado pelo contraste a e pela extensão b , ou seja, qual a relação entre a , b e σ que satisfaça a condição

$$C_{\max}(x, \sigma) > T \quad (\text{AII.4})$$

Substituindo (AII.3) e (AII.1) em (AII.2):

$$C(x, \sigma) = \int_{-\infty}^{b/2} 0 \cdot \frac{1}{\sigma \sqrt{2\pi}} \cdot e^{-\frac{(t-x)^2}{2\sigma^2}} dt + \int_{-b/2}^{b/2} a \cdot \frac{1}{\sigma \sqrt{2\pi}} \cdot e^{-\frac{(t-x)^2}{2\sigma^2}} dt + \int_{b/2}^{\infty} 0 \cdot \frac{1}{\sigma \sqrt{2\pi}} \cdot e^{-\frac{(t-x)^2}{2\sigma^2}} dt$$

$$C(x, \sigma) = a \int_{-b/2}^{b/2} \frac{1}{\sigma \sqrt{2\pi}} \cdot e^{-\frac{(t-x)^2}{2\sigma^2}} dt \quad (\text{AII.5})$$

$$\text{Fazendo: } Z = \frac{t-x}{\sigma}, \quad \begin{cases} dZ = \frac{dt}{\sigma} \\ dt = \sigma \cdot dZ \end{cases} \quad (\text{AII.6})$$

$$C(x, \sigma) = \frac{a}{\sigma \sqrt{2\pi}} \int_{-\left(\frac{b/2-x}{\sigma}\right)}^{\left(\frac{b/2-x}{\sigma}\right)} e^{-\frac{Z^2}{2}} \cdot \sigma \cdot dZ = \frac{a}{\sqrt{2\pi}} \int_{-\left(\frac{b/2-x}{\sigma}\right)}^{\left(\frac{b/2-x}{\sigma}\right)} e^{-\frac{Z^2}{2}} \cdot dZ \quad (\text{AII.7})$$

Será determinado o valor de $C(x)$ para o dois pontos, o ponto central e a borda.

Valor da convolução no ponto central, $x=0$:

$$t = b/2 \Rightarrow Z = b/2\sigma$$

$$t = -b/2 \Rightarrow Z = -b/2\sigma$$

$$C(0, \sigma) = a \cdot \underbrace{\frac{1}{\sqrt{2\pi}} \int_{-b/2\sigma}^{b/2\sigma} e^{-\frac{Z^2}{2}} dZ}_{N(0,1) \Big|_{-b/2\sigma}^{b/2\sigma}} \quad (\text{AII.8})$$

A porção destacada de (AII.8) representa uma distribuição normal padrão, com média zero e desvio padrão um, $N(0,1)$. Em particular, representa a área sob a normal, entre os pontos $-b/2\sigma$ e $b/2\sigma$, apresentada na figura AII.3.

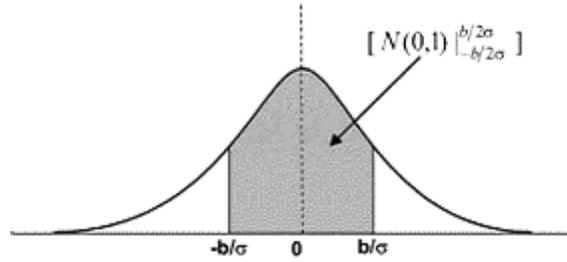


Figura AII.3. Função normal com média zero e desvio padrão 1. A área destacada sob a

curva é dada por: $\frac{1}{\sqrt{2\pi}} \int_{-b/2\sigma}^{b/2\sigma} e^{-\frac{z^2}{2}} dz$

$$\therefore C(0, \sigma) = a \cdot \text{Área}[N(0,1) |_{-b/2\sigma}^{b/2\sigma}] \quad (\text{AII.9})$$

Valor da convolução na borda, $x=b/2$

$$t = b/2 \Rightarrow Z = 0$$

$$t = -b/2 \Rightarrow Z = -b/\sigma$$

$$C(b/2, \sigma) = \frac{a}{\sqrt{2\pi}} \cdot \int_{-b/\sigma}^0 e^{-\frac{z^2}{2}} dz = a \underbrace{\frac{1}{\sqrt{2\pi}} \cdot \int_{-b/\sigma}^0 e^{-\frac{z^2}{2}} dz}_{N(0,1) |_{-b/\sigma}^0} \quad (\text{AII.10})$$

A parte destacada de 10 representa a área sob a normal, entre os pontos $-b/\sigma$ e zero, conforme apresentado na figura AII.4.

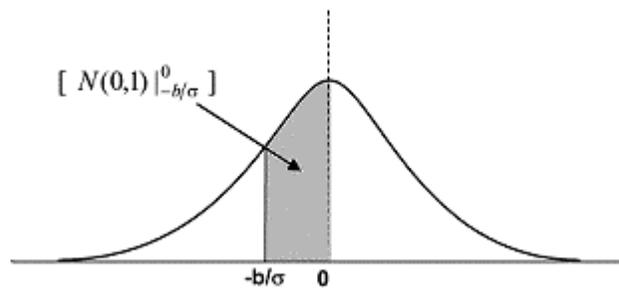


Figura AII.4. Função normal com média zero e desvio padrão 1. A área destacada sob a

curva é dada por: $\frac{1}{\sqrt{2\pi}} \int_{-b/2\sigma}^0 e^{-\frac{z^2}{2}} dz$

$$\therefore C(b/2, \sigma) = a \cdot \text{Área}[N(0,1) |_{-b/\sigma}^0] = a \cdot \text{Área}[N(0,1) |_0^{b/\sigma}] \quad (\text{AII.11})$$

Aplicação do operador limiar

O valor de cada ponto da função em uma determinada escala é o resultado da convolução entre a função, $f(x)$, e a gaussiana com desvio padrão σ . O resultado da convolução depende de a , b e σ . Aqui serão analisados os valores para dois pontos: o ponto central ($x=0$) e os pontos de borda ($x=b/2$).

Para detecção desses pontos será utilizada a função limiar, dada pela expressão AII.4. Na formulação seguir, um ponto da função $f(x)$ é considerado um ponto da estrutura caso ele satisfaça a condição expressa em AII.12:

$$f(x) \geq T, \quad T \geq \frac{1}{3} a \quad (\text{AII.12})$$

Análise nos Pontos de Borda

O valor da convolução nos pontos de borda é dado pela expressão AII.10. Uma tabela com os valores da área delimitada pela curva normal standard até um ponto x é encontrada em (Spiegel 1973):

$$\text{Area}(x) = \frac{1}{\sqrt{2\pi}} \cdot \int_{-\infty}^x e^{-\frac{t^2}{2}} dt.$$

O valor da convolução procurado em AII.11 pode ser obtido por:

$$\text{Area}|_0^{b/\sigma} = \frac{1}{\sqrt{2\pi}} \cdot \int_0^{b/\sigma} e^{-\frac{t^2}{2}} dt - \frac{1}{\sqrt{2\pi}} \cdot \int_{-\infty}^0 e^{-\frac{t^2}{2}} dt$$

Tabela AII.1. Valores de área sob a curva normal, com a porção de área ($-\infty \rightarrow 0$) subtraída.

b/σ	σ/b	Área[$N(0,1) _0^{b/\sigma}$]	$C(b/2)$ (AII.10)
0,1	10	0,0398	$a \cdot \text{Area}$
0,25	4	0,0987	$a \cdot \text{Area}$
1	1	0,3413	$a \cdot \text{Area}$
1,96	0,51	0,4750	$a \cdot \text{Area}$
2,0	0,5	0,4772	$a \cdot \text{Area}$
3,0	0,33	0,4987	$a \cdot \text{Area}$
4,0	0,25	0,5000	$a \cdot \text{Area}$

Na tabela 1 são apresentados os valores de área delimitados pela curva normal standard, obtidos a partir de (Spiegel, 1973), já subtraída a porção de $(-\infty \rightarrow 0)$.

Pela condição AII.12: $C(\pm b/2) > \frac{a}{3}$

Deve-se, portanto, procurar na tabela 1, o valor de b/σ para o qual seja satisfeita a condição

$$\text{Área}[N(0,1)|_0^{b/\sigma}] \cong 0.33 \quad (\text{AII.13})$$

A condição (AII.13) é satisfeita no ponto $\frac{b}{\sigma} = 1$

$$\text{Assim :} \quad T > \frac{1}{3} a \Rightarrow \frac{b}{\sigma} \geq 1$$

$$\boxed{\therefore \sigma \leq b} \quad (\text{AII.14})$$

Análise no Ponto Central

Fazendo uma análise equivalente para o ponto central ($x=0$), o valor de convolução dado por AII.9, pode obtido a partir dos valores da tabela 2 (Spiegel, 1973).

Tabela AII.2. Valores de área sob a curva normal, com a porção de área $(-\infty \rightarrow -b/2\sigma)$ subtraída.

$b/2\sigma$	σ	$\text{Área}[N(0,1) _0^{b/\sigma}]$	$C(0)$ (AII.11)
0,1	5b	0,0796	<i>a . Area</i>
0,25	2b	0,1974	<i>a . Area</i>
0,43	1,16b	0,334	<i>a . Area</i>
0,5	b	0,3830	<i>a . Area</i>
1	0,5b	0,6826	<i>a . Area</i>
2,0	0,5	0,9500	<i>a . Area</i>
4,0	0,25	1,000	<i>a . Area</i>

Usando o mesmo raciocínio do caso anterior para $C(0)$, encontra-se a solução da condição (AII.12) no ponto $\frac{b}{2\sigma} = 0,43$.

$$\text{Assim :} \quad T > \frac{1}{3} a \Rightarrow \frac{b}{2\sigma} \geq 0,43$$

$$\boxed{\therefore \sigma \leq 1,16 b} \quad (\text{AII.15})$$

Conclusão: Utilizando função limiar, com a condição $T > 1/3 a$, a estrutura será detectada em pelo menos um ponto (o central) para valores de σ até $1,16b$. Os seus pontos de borda serão determinados para valores de σ até b . Até este valor de σ , a estrutura será detectada com as mesmas dimensões que a imagem original.

Validação

Os resultados obtidos neste item foram validados utilizando o software Matlab®. Foi gerada uma função teste simples, para verificar a validade do resultado. A função, apresentada na figura AII.5, é definida por:

$$f(x) = \begin{cases} 10 & 75 \leq x \leq 125 \\ 0 & \text{caso contrário} \end{cases} \quad (\text{AII.16})$$

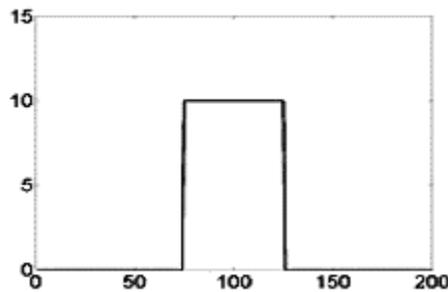


Figura AII.5. Função unidimensional utilizada para testar os resultados obtidos nas relações para b/σ .

A função limiar aplicada vale: $T > 3,3$.

Para avaliar o resultado nos pontos de borda (expressão AII.14), foi feita a convolução com uma gaussiana com valor de $\sigma = 50$. O resultado, apresentado na figura AII.6^{AII.1}, mostra-se compatível com a condição colocada.

Para avaliar o resultado no ponto central (expressão AII.15), foi feita a convolução com uma gaussiana com valor de $\sigma = 58$. O resultado, apresentado na figura AII.7, mostra-

^{AII.1} Os valores da função foram ajustados na figura para que o valor central seja em zero.

se compatível com a condição colocada. A partir desse valor de σ nenhum ponto da função é detectado.

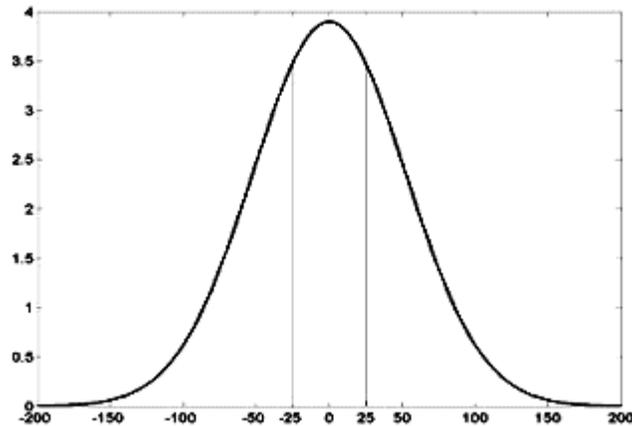


Figura AII.6. Resultado da convolução da função dada por AII.16 e a gaussiana com $\sigma = 50$ (condição AII.14 – pontos de borda). A partir deste valor de σ , a estrutura detectada utilizando o limiar $T = a/3$ é menor do que a original. Os resultados foram ajustados para que o valor central da função seja zero.

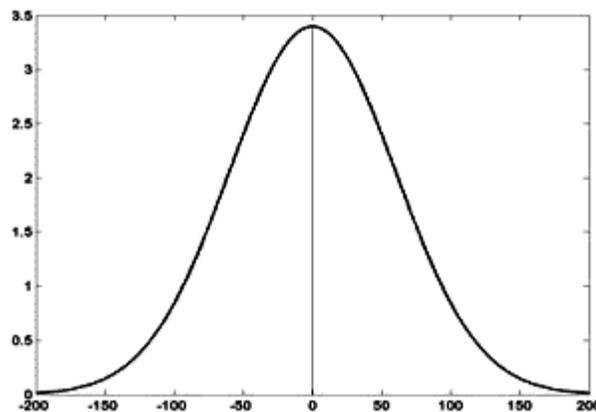


Figura AII.7. Resultado da convolução da função dada por AII.16 e a gaussiana com $\sigma = 58$ (condição AII.15 – ponto central). A partir deste valor de σ , a estrutura não é mais detectada. Os resultados foram ajustados para que o valor central da função seja zero.

b. caso de 2 estruturas

Neste item, deseja-se avaliar a possibilidade de determinar *a priori* o valor máximo de σ para que, em um sinal com 2 estruturas, elas possam ser detectadas como objetos

distintos. O objetivo desta formulação é encontrar uma relação entre σ e os parâmetros que caracterizam as duas estruturas, de tal forma que ambas sejam detectadas. Para simplificar a análise, as duas estruturas consideradas têm a mesma amplitude (a) e extensão (b). Considera-se que as duas estruturas estão separadas por uma distância $d = b$. O sinal $f(x)$, dado pela expressão AII.17, é apresentado na figura AII.8.

$$f(x) = \begin{cases} a & x \leq |b/2| \\ a & 3b/2 < x < 5b/2 \\ 0 & \text{caso contrário} \end{cases} \quad (\text{AII.17})$$

Como no caso anterior, será utilizada uma função limiar simples para a detecção das estruturas. Para um dado limiar T , interessa obter os valores de σ tais que a aplicação da função de convolução (AII.3) com a gaussiana permita a detecção dos dois objetos, caracterizados pelo contraste a e extensão b .

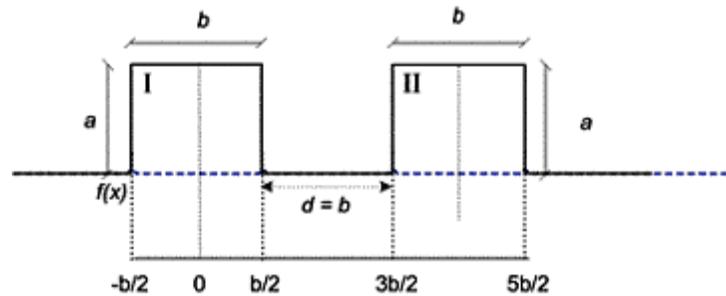


Figura AII.8. Sinal uni-dimensional, no qual se deseja detectar as duas ondas quadradas.

Na figura AII.9 apresentam-se 3 níveis do espaço de escalas da função apresentada em AII.8. As duas estruturas sofrem um processo de suavização progressiva, para valores crescentes de σ . A aplicação da função limiar para detecção de estruturas resulta em objetos detectados com raio $R(\sigma)$, progressivamente crescente. Na figura, o limiar é a linha horizontal de valor T , e os objetos detectados são as porções retangulares cinzas. A partir de um determinado nível de suavização, as duas estruturas começam a se sobrepor (c). Com o aumento da suavização das estruturas, o limiar ocorre na região de sobreposição e as duas estruturas passam a ser detectadas como apenas uma entidade (d).

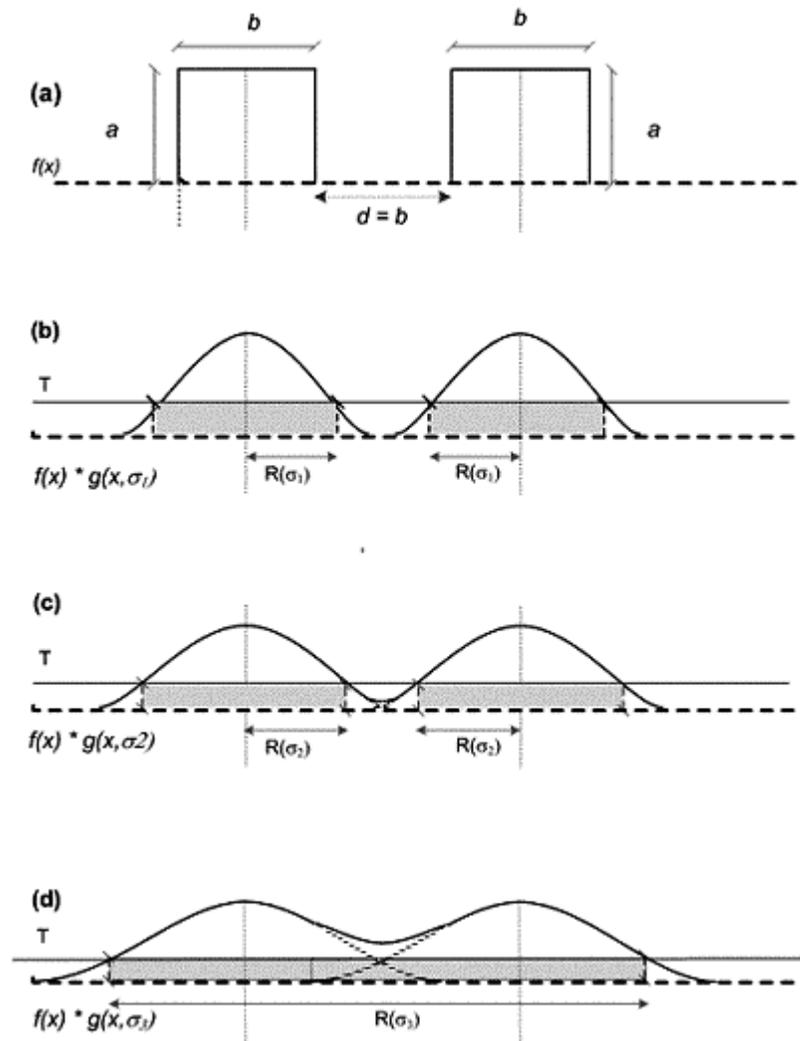


Figura AII.9. Seqüência de eventos em um espaço de escalas construído para um sinal unidimensional $f(x)$ apresentado em (a). (b), (c) e (d) mostram níveis mais altos desse espaço de escalas. A detecção das estruturas é feita utilizando a função limiar. Nas figuras (b) e (c) as estruturas presentes no sinal original são detectadas como estruturas distintas. Em (d) há um acoplamento, devido ao borrimento produzido pela convolução com a gaussiana.

A partir de um determinado σ , o valor da convolução do sinal $f(x)$ com a gaussiana no ponto intermediário entre as duas estruturas (b) atinge o valor do limiar T e ocorre o acoplamento das duas estruturas. O problema é encontrar o valor de σ , para o qual $C(b, \sigma) = T$. A expressão (AII.5), que apresenta o valor da convolução para uma estrutura, pode ser re-escrita no caso de duas estruturas:

$$C(x, \sigma) = a \int_{-b/2}^{b/2} \frac{1}{\sigma \sqrt{2\pi}} \cdot e^{-\frac{(t-x)^2}{2\sigma^2}} dt + a \int_{3b/2}^{5b/2} \frac{1}{\sigma \sqrt{2\pi}} \cdot e^{-\frac{(t-x)^2}{2\sigma^2}} dt \quad (\text{AII.15})$$

$$\text{fazendo } z = \frac{t-x}{\sigma}, \quad \begin{cases} dz = \frac{dt}{\sigma} \\ dt = \sigma \cdot dz \end{cases}$$

$$\begin{cases} t_1 = -\frac{b}{2} \Rightarrow z_1 = \frac{-b/2 - x}{\sigma} \\ t_2 = \frac{b}{2} \Rightarrow z_2 = \frac{b/2 - x}{\sigma} \\ t_3 = \frac{3b}{2} \Rightarrow z_3 = \frac{3b/2 - x}{\sigma} \\ t_4 = \frac{5b}{2} \Rightarrow z_4 = \frac{5b/2 - x}{\sigma} \end{cases} \quad \text{para } x = b \Rightarrow \begin{cases} z_1 = -\frac{3b}{2\sigma} \\ z_2 = -\frac{b}{2\sigma} \\ z_3 = \frac{b}{2\sigma} \\ z_4 = \frac{3b}{2\sigma} \end{cases}$$

$$\therefore C(b, \sigma) = a \cdot \frac{1}{\sqrt{2\pi}} \int_{-3b/2\sigma}^{-b/2\sigma} e^{-\frac{z^2}{2}} dz + a \cdot \frac{1}{\sqrt{2\pi}} \int_{b/2\sigma}^{3b/2\sigma} e^{-\frac{z^2}{2}} dz$$

$$C(b, \sigma) = a \int_{-3b/2\sigma}^{-b/2\sigma} N(0,1) dz + a \int_{b/2\sigma}^{3b/2\sigma} N(0,1) dz = 2 \cdot a \int_{b/2\sigma}^{3b/2\sigma} N(0,1) dz \quad (\text{AII.16})$$

A expressão AII.16 representa a soma de duas área sob a normal, entre os pontos $(-3b/2\sigma, -b/2\sigma)$ e $(b/2\sigma, 3b/2\sigma)$, apresentadas na figura AII.10.

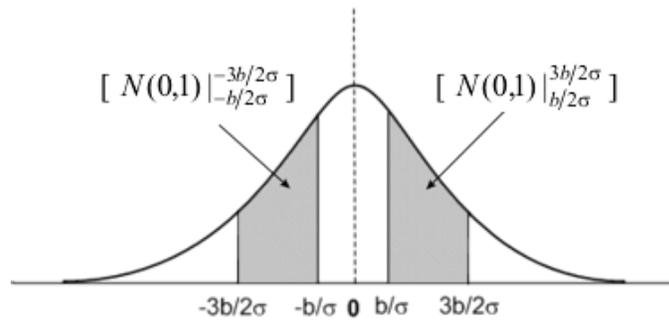


Figura AII.10. Função normal com média zero e desvio padrão 1. As áreas destacadas

sob a curva são dadas por: $\frac{1}{\sqrt{2\pi}} \int_{-3b/2\sigma}^{-b/2\sigma} e^{-\frac{z^2}{2}} dz$ e $\frac{1}{\sqrt{2\pi}} \int_{b/2\sigma}^{3b/2\sigma} e^{-\frac{z^2}{2}} dz$

Para satisfazer a condição AII.12:

$$\frac{a}{3} \leq 2.a. \int_{b/2\sigma}^{3b/2\sigma} N(0,1) dz = 2.a. \left(\int_0^{3b/2\sigma} N(0,1) dz - \int_0^{b/2\sigma} N(0,1) dz \right) \quad (\text{AII.16})$$

O problema é determinar b/σ para que (AII.16) seja satisfeita. Será utilizada a função erro ($erf(x)$), que é definida como:

$$erf(u) \equiv \frac{2}{\sqrt{\pi}} \int_0^u e^{-x^2} dx$$

$$\text{fazendo } u' = \sqrt{2}u \Rightarrow erf(u) \equiv 2 \int_0^{\sqrt{2}u} N(0,1) dz$$

$$\frac{1}{2} erf(u'/\sqrt{2}) = \int_0^{u'} N(0,1) dz \quad (\text{AII.17})$$

Substituindo (AII.17) em (AII.16):

$$\frac{1}{3} = erf\left(\frac{3b}{2\sqrt{2}\sigma}\right) - erf\left(\frac{b}{2\sqrt{2}\sigma}\right)$$

$$\text{Seja: } r = \frac{b}{2\sqrt{2}\sigma} \quad (\text{AII.18})$$

$$f(r) = erf(3r) - erf(r) - 1/3 \quad (\text{AII.19})$$

A função é apresentada na figura AII.11.

As soluções da equação para $f(r) = 0$ fornecem os valores de σ que obedecem a condição estabelecida para o valor da convolução (AII.12). As soluções da equação AII.19 podem ser obtidas utilizando a função 'fzero()' do software MatLab:

$$r_1 = 0,1661 \text{ e } r_2 = 0,6784$$

Substituindo os dois valores de r em (AII.18), obtém-se as duas relações:

$$\sigma_1 \cong 2,13b \text{ e } \sigma_2 \cong 0,52b \quad (\text{AII.20})$$

Os dois valores de σ correspondem a dois momentos distintos, nos quais o valor da convolução no ponto b tem o valor igual ao limiar:

- no primeiro momento (σ menor), ocorre o acoplamento das duas estruturas;
- no segundo momento (σ maior), a amplitude da estrutura formada pelo acoplamento das duas anteriores torna-se menor que o valor limiar.

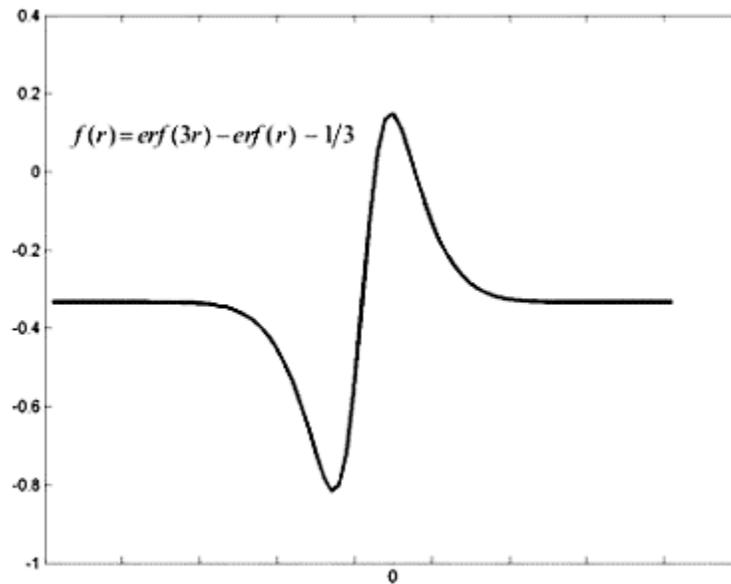


Figura AII.11. Função erro, cujas soluções fornecem os valores de σ para a condição AII.12. Função obtida utilizando o software Matlab®.

Conclusão: Utilizando função limiar, com a condição $T > 1/3a$, as duas estruturas serão detectadas como entidades distintas para valores de σ até $0,52b$. A partir desse momento, as duas estruturas se acoplam, formando uma única entidade, que será detectada até valores de $\sigma = 2,13$. A partir desse valor, nenhuma estrutura é detectada no sinal.

Validação

Os resultados obtidos neste item foram validados utilizando o software Matlab®. Foi gerada uma função teste simples, para verificar a validade do resultado. A função, apresentada na figura AII.12, é definida por:

$$f(x) = \begin{cases} 10 & 25 \leq x \leq 75 \\ 10 & 125 < x < 175 \\ 0 & \text{caso contrário} \end{cases} \quad (\text{AII.21})$$

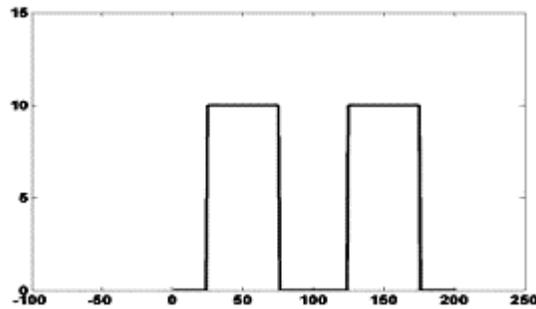


Figura AII.12. Função unidimensional utilizada para testar os resultados obtidos nas relações para b/σ , no caso de duas estruturas.

Na figura AII.13 são apresentadas oito escalas do espaço de escalas do sinal.

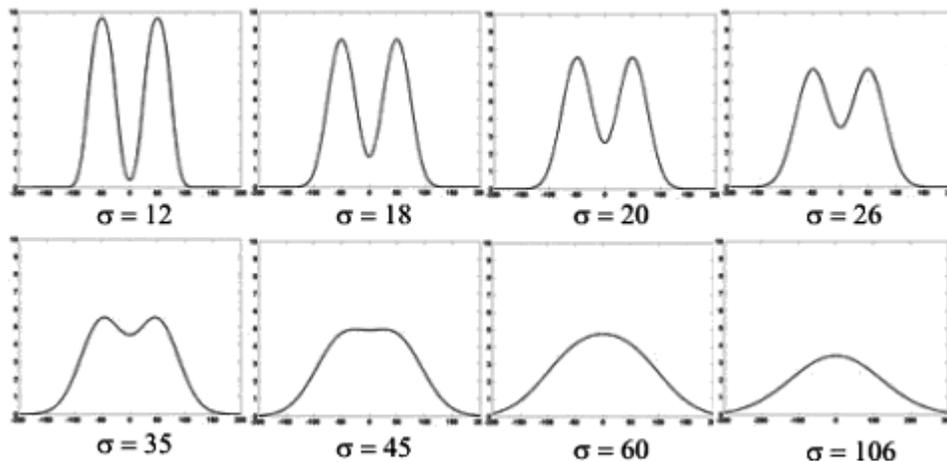


Figura AII.13. Espaço de escalas da função apresentada na figura AII.12 para oito valores de σ .

A função limiar aplicada vale: $T > 3,3$. Para avaliar os resultados obtidos na expressão AII.20, foi feita a convolução com uma gaussiana com os dois valores de σ . Com a aplicação de $\sigma_2 = 2,13b = 0,52 * 50 = 106,5$, obteve-se o resultado apresentado na figura AII.14. Nessa escala, só resta uma estrutura que é resultado do acoplamento das duas iniciais. A partir dessa amplitude (3,3) nenhuma estrutura é detectada no sinal. Com a

aplicação de $\sigma_2 = 0,52b = 0,52 * 50 = 26$, obteve-se o resultado apresentado na figura AII.15. Nessa escala, o ponto intermediário entre as duas estruturas passa a apresentar um valor mais alto do que o limiar, e elas passam a ser detectadas como uma única entidade.

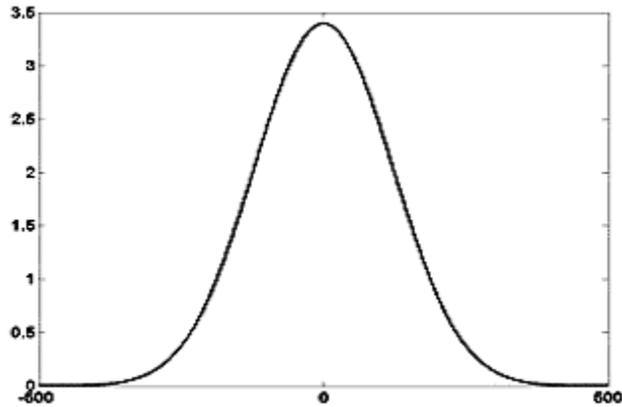


Figura AII.14. Resultado da convolução da função dada por AII.21 e a gaussiana com $\sigma = 106.5$. A partir deste valor de σ , nenhuma estrutura é detectada no sinal. Os resultados foram ajustados para que o valor central da função seja zero.

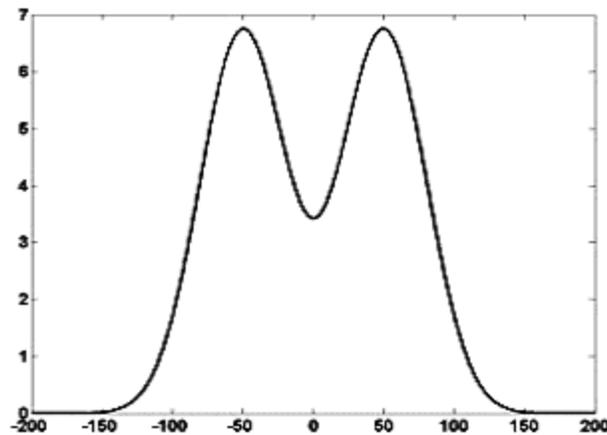


Figura AII.15. Resultado da convolução da função dada por AII.21 e a gaussiana com $\sigma = 26$. A partir deste valor de σ , as duas estruturas se acoplam. Os resultados foram ajustados para que o valor central da função seja zero.

Caso 2. Detecção de estruturas em imagens 2D feita a partir do operador *umbilicity*

Seja uma imagem definida pela função $f(x,y)$, apresentada na figura AII.16:

$$f(r \cos \theta, r \sin \theta) = a, \text{ para } 0 \leq r \leq R \quad (\text{AII.22})$$

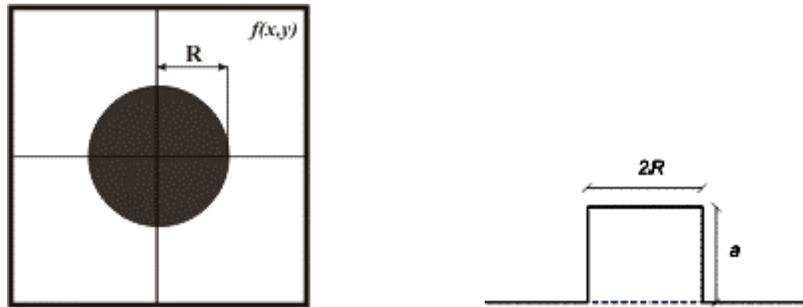


Figura AII.16. Imagem bidimensional com uma estrutura de raio R e amplitude a no centro da imagem.

Da mesma forma que no caso 1, deseja-se detectar a estrutura presente na imagem, através de um operador. A figura AII.17 apresenta uma representação esquemática do processo:

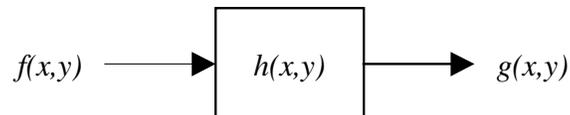


Figura AII.17. Processo de detecção de estruturas através da utilização de um operador $h(x,y)$.

O operador $h(x,y)$ é o responsável pela detecção da estrutura da imagem apresentada na figura 1. A aplicação é feita pela operação de convolução em 2 dimensões:

$$g(x, y) = f(x, y) \otimes h(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(t_1, t_2) \cdot h(x - t_1, y - t_2) dt_1 dt_2 \quad (\text{AII.23})$$

No capítulo 3, expressão (3.9) foi apresentada uma expressão geral para um operador de escala diferencial em duas dimensões::

$$h_{m,n}(x, y, \sigma) = \frac{\partial^{n+m} g_{m,n}(x, y, \sigma)}{\partial x^n \partial y^m} \quad (\text{AII.24})$$

σ é o parâmetro de escala e $g_{m,n}(x, y, \sigma)$ é a função gaussiana bidimensional:

$$g(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{1}{2}\left(\frac{x^2+y^2}{\sigma^2}\right)} \quad (\text{AII.25})$$

O operador utilizado neste trabalho é o operador *umbilicity*, que em 2D é dado pela expressão (Florack, 1992) :

$$U_{2D} = \frac{2(L_{xx}L_{yy} - L_{xy}L_{yx})}{L_{xx}^2 + 2L_{xy}L_{yx} + L_{yy}^2}$$

Utilizando o operador *umbilicity* (apenas o numerador, o denominador é apenas para normalização) em (AII.24), obtém-se o operador *umbilicity* diferencial $u(x, y, \sigma)$:

$$u(x, y, \sigma) = (L_{xx}L_{yy} - L_{xy}L_{yx})g(x, y, \sigma) \quad (\text{AII.26})$$

$$\therefore u(x, y, \sigma) = L_{xx}g(x, y, \sigma).L_{yy}g(x, y, \sigma) - L_{xy}g(x, y, \sigma).L_{yx}g(x, y, \sigma) \quad (\text{AII.27})$$

Os operadores L_{xx} , L_{yy} e L_{zz} são dados por:

$$L_{xx} = \frac{\partial^2}{\partial x^2}; L_{yy} = \frac{\partial^2}{\partial y^2}; L_{xy} = L_{yx} = \frac{\partial^2}{\partial x \partial y} \quad (\text{AII.28})$$

Substituindo os valores de AII.28 em cada um dos termos da equação (AII.27):

$$L_x g(x, y) = \frac{\partial}{\partial x} \left(\frac{1}{2\pi\sigma^2} e^{-\frac{1}{2} \left(\frac{x^2+y^2}{\sigma^2} \right)} \right) = \frac{1}{2\pi\sigma^2} e^{-\frac{1}{2} \left(\frac{x^2+y^2}{\sigma^2} \right)} \cdot \left(-\frac{1}{2\sigma^2} \right) (2x)$$

$$\therefore L_x g(x, y) = \frac{1}{2\pi\sigma^4} \cdot x \cdot e^{-\frac{1}{2} \left(\frac{x^2+y^2}{\sigma^2} \right)} \quad (\text{AII.29})$$

$$L_y g(x, y) = \frac{\partial}{\partial y} \left(\frac{1}{2\pi\sigma^2} e^{-\frac{1}{2} \left(\frac{x^2+y^2}{\sigma^2} \right)} \right) = \frac{1}{2\pi\sigma^2} e^{-\frac{1}{2} \left(\frac{x^2+y^2}{\sigma^2} \right)} \cdot \left(-\frac{1}{2\sigma^2} \right) (2y)$$

$$\therefore L_y g(x, y) = \frac{1}{2\pi\sigma^4} \cdot y \cdot e^{-\frac{1}{2} \left(\frac{x^2+y^2}{\sigma^2} \right)} \quad (\text{AII.30})$$

$$L_{xx} g(x, y) = \frac{1}{2\pi\sigma^4} \left[e^{-\frac{1}{2} \left(\frac{x^2+y^2}{\sigma^2} \right)} + x \cdot e^{-\frac{1}{2} \left(\frac{x^2+y^2}{\sigma^2} \right)} \cdot \left(-\frac{1}{2\sigma^2} \right) (2x) \right]$$

$$\therefore L_{xx} g(x, y) = \frac{1}{2\pi\sigma^4} \cdot e^{-\frac{1}{2} \left(\frac{x^2+y^2}{\sigma^2} \right)} \left[1 - \frac{x^2}{\sigma^2} \right] \quad (\text{AII.31})$$

$$L_{yy} g(x, y) = \frac{1}{2\pi\sigma^4} \left[e^{-\frac{1}{2} \left(\frac{x^2+y^2}{\sigma^2} \right)} + y \cdot e^{-\frac{1}{2} \left(\frac{x^2+y^2}{\sigma^2} \right)} \cdot \left(-\frac{1}{2\sigma^2} \right) (2y) \right]$$

$$\therefore L_{yy} g(x, y) = \frac{1}{2\pi\sigma^4} \cdot e^{-\frac{1}{2} \left(\frac{x^2+y^2}{\sigma^2} \right)} \left[1 - \frac{y^2}{\sigma^2} \right] \quad (\text{AII.32})$$

$$L_{xy} g(x, y) = L_{yx} g(x, y) = \frac{1}{2\pi\sigma^4} \cdot x \cdot e^{-\frac{1}{2} \left(\frac{x^2+y^2}{\sigma^2} \right)} \cdot \left(-\frac{1}{2\sigma^2} \right) 2y$$

$$\therefore L_{xy} g(x, y) = L_{yx} g(x, y) = -\frac{1}{2\pi\sigma^6} \cdot x \cdot y \cdot e^{-\frac{1}{2} \left(\frac{x^2+y^2}{\sigma^2} \right)} \quad (\text{AII.33})$$

Substituindo (AII.31), (AII.32) e (AII.33) em (AII.27), tem-se:

$$\begin{aligned}
u(x, y, \sigma) &= \left(\frac{1}{2\pi\sigma^4} \cdot e^{-\frac{1}{2}\left(\frac{x^2+y^2}{\sigma^2}\right)} \left[1 - \frac{x^2}{\sigma^2} \right] \cdot \frac{1}{2\pi\sigma^4} \cdot e^{-\frac{1}{2}\left(\frac{x^2+y^2}{\sigma^2}\right)} \left[1 - \frac{y^2}{\sigma^2} \right] \right) - \left(-\frac{1}{2\pi\sigma^6} \cdot x \cdot y \cdot e^{-\frac{1}{2}\left(\frac{x^2+y^2}{\sigma^2}\right)} \right)^2 \\
u(x, y, \sigma) &= \left(\frac{1}{2\pi\sigma^4} \cdot e^{-\frac{1}{2}\left(\frac{x^2+y^2}{\sigma^2}\right)} \right)^2 \left(\left[1 - \frac{x^2}{\sigma^2} \right] \cdot \left[1 - \frac{y^2}{\sigma^2} \right] \right) - \left(-\frac{x \cdot y}{\sigma^2} \cdot \frac{1}{2\pi\sigma^4} \cdot e^{-\frac{1}{2}\left(\frac{x^2+y^2}{\sigma^2}\right)} \right)^2 \\
u(x, y, \sigma) &= \left(\frac{1}{2\pi\sigma^4} \cdot e^{-\frac{1}{2}\left(\frac{x^2+y^2}{\sigma^2}\right)} \right)^2 \left(\left[1 - \frac{x^2}{\sigma^2} \right] \cdot \left[1 - \frac{y^2}{\sigma^2} \right] \right) - \left(-\frac{x \cdot y}{\sigma^2} \right)^2 \\
u(x, y, \sigma) &= \left(\frac{e^{-\frac{1}{2}\left(\frac{x^2+y^2}{\sigma^2}\right)}}{2\pi\sigma^4} \right)^2 \left(1 - \frac{y^2}{\sigma^2} - \frac{x^2}{\sigma^2} + \frac{x^2 y^2}{\sigma^4} - \frac{x^2 y^2}{\sigma^4} \right) \\
u(x, y, \sigma) &= \left(\frac{e^{-\frac{1}{2}\left(\frac{x^2+y^2}{\sigma^2}\right)}}{2\pi\sigma^4} \right)^2 \left(1 - \frac{x^2 + y^2}{\sigma^2} \right) \tag{AII.34}
\end{aligned}$$

fazendo uma transformação para coordenadas polares :

$$\begin{cases} x = r \cdot \cos \theta \\ y = r \cdot \sin \theta \end{cases} \quad \text{ou} \quad \begin{cases} r = \sqrt{x^2 + y^2} \\ \theta = \arctan(y/x) \end{cases}$$

$$u_\theta(r, \sigma) = \left(\frac{e^{-\frac{1}{2}\left(\frac{r^2}{\sigma^2}\right)}}{2\pi\sigma^4} \right)^2 \left(1 - \frac{r^2}{\sigma^2} \right) \tag{AII.35}$$

Em (AII.23), para o operador *umbilicity*, $h(x, y) = u(x, y)$

$$g(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(t_1, t_2) \cdot u(x-t_1, y-t_2) dt_1 dt_2$$

e mudando para coordenadas polares: $\begin{cases} t1 = r \cdot \cos \theta \\ t2 = r \cdot \sen \theta \end{cases}$

$$g(x, y) = \int_0^{2\pi} \int_0^{\infty} \underbrace{f(r \cos \theta, r \sen \theta)}_{a, 0 \leq r \leq R} \cdot u(x - r \cos \theta, y - r \sen \theta) r dr d\theta$$

$$g(x, y) = \int_0^{2\pi} \int_0^R a \cdot u(x - r \cos \theta, y - r \sen \theta) r dr d\theta$$

$$g(x, y) = \frac{a}{(2\pi\sigma^4)^2} \int_0^{2\pi} \int_0^R r \cdot e^{-\left(\frac{(x-r\cos\theta)^2 + (y-r\sen\theta)^2}{\sigma^2}\right)} \cdot \left(1 - \frac{(x-r\cos\theta)^2 + (y-r\sen\theta)^2}{\sigma^2}\right) dr d\theta$$

$$g(x, y) = \frac{a}{(2\pi\sigma^4)^2} \int_0^{2\pi} \int_0^R r \cdot \left(e^{-\left(\frac{x^2 - 2 \cdot x \cdot r \cdot \cos \theta + r^2 \cos^2 \theta + y^2 - 2 \cdot y \cdot r \cdot \sen \theta + r^2 \sen^2 \theta}{\sigma^2}\right)} \right)^2 \cdot \left(1 - \frac{x^2 - 2 \cdot x \cdot r \cdot \cos \theta + r^2 \cos^2 \theta + y^2 - 2 \cdot y \cdot r \cdot \sen \theta + r^2 \sen^2 \theta}{\sigma^2}\right) dr d\theta$$

$$g(x, y) = \frac{a}{(2\pi\sigma^4)^2} \int_0^{2\pi} \int_0^R r \cdot e^{-\left(\frac{x^2 + y^2 + r^2 - 2 \cdot r(x \cdot \cos \theta + y \cdot \sen \theta)}{\sigma^2}\right)} \cdot \left(1 - \frac{x^2 + y^2 + r^2 - 2 \cdot r(x \cdot \cos \theta + y \cdot \sen \theta)}{\sigma^2}\right) dr d\theta \quad (\text{AII.36})$$

Avaliando a expressão $g(x, y)$ no ponto $(x, y) = (0, 0)$

$$g(0, 0) = \frac{a}{(2\pi\sigma^4)^2} \int_0^{2\pi} \int_0^R r \cdot e^{-\left(\frac{r^2}{\sigma^2}\right)} \left(1 - \frac{r^2}{\sigma^2}\right) dr d\theta = \frac{2\pi a}{(2\pi\sigma^4)^2} \int_0^R r \cdot e^{-\left(\frac{r^2}{\sigma^2}\right)} \cdot \left(1 - \frac{r^2}{\sigma^2}\right) dr$$

$$g(0, 0) = \frac{a}{2\pi\sigma^8} \int_0^R r \cdot e^{-\left(\frac{r^2}{\sigma^2}\right)} \left(1 - \frac{r^2}{\sigma^2}\right) dr \quad (\text{AII.37})$$

Fazendo:

$$s = \frac{r}{\sigma} \Rightarrow ds = \frac{dr}{d\sigma}$$

$$g(0,0) = \frac{a}{2\pi\sigma^8} \int_0^{R/\sigma} \sigma s (1-s^2) e^{-s^2} \cdot \sigma \cdot ds$$

$$g(0,0) = \frac{a}{2\pi\sigma^6} \int_0^{R/\sigma} s (1-s^2) e^{-s^2} ds \quad (\text{AII.38})$$

A função $g(0,0)$ pode ser re-escrita como:

$$g(0,0) = \frac{a}{2\pi\sigma^6} I(R/\sigma) \quad (\text{AII.39})$$

$$I(R/\sigma) = \int_0^{R/\sigma} \sigma s (1-s^2) e^{-s^2} \cdot \sigma \cdot ds \quad (\text{AII.40})$$

O gráfico da função (AII.40) é apresentado na figura (AII.18), a seguir.

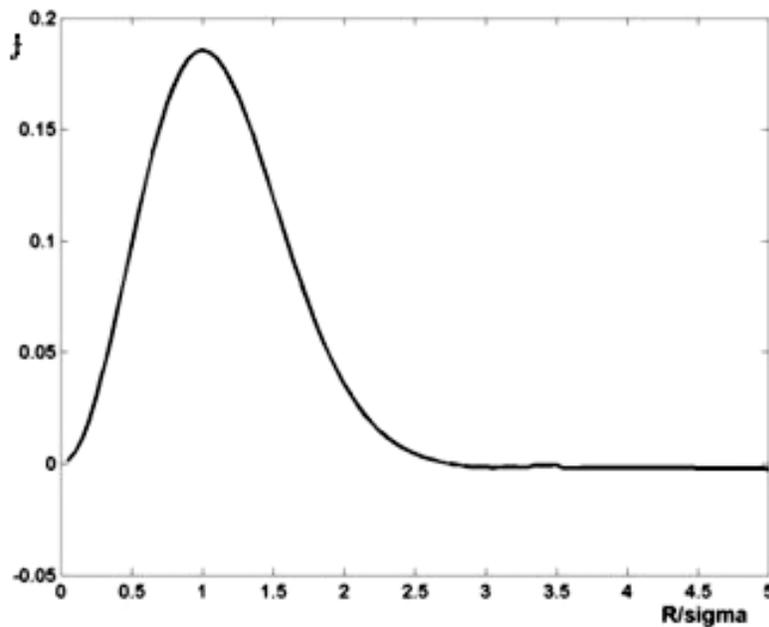


Figura AII.18. Função $I(R/\sigma)$ para o ponto (0,0). A solução para $I = 0$ fornece o valor de σ para a condição AII.38. Função obtida utilizando o software Matlab®.

O GLblob será detectado no ponto (0,0) da figura para os pontos na função para os quais a função *umbilicity* é maior que zero. Para a solução do problema é necessário, então, encontrar a solução para $I(R/\sigma)=0$.

A expressão (AII.40) foi implementada utilizando o software Matlab®. A integração numérica permite a obtenção dos valores para a construção da figura AII.18. Os valores da integração fornecem a solução de $g(0,0) = 0$ no ponto:

$$\frac{R}{\sigma} = 2,75$$

$$\therefore \sigma = \frac{R}{2,75} \Rightarrow \sigma \cong 0,36R \quad (\text{AII.41})$$

Teoricamente, portanto, para valores de $\sigma \geq 0,36R$, o ponto (0,0) é detectado pelo o operador *umbilicity*. A constante que multiplica a função $I(R/\sigma)$ na expressão (AII.39) não modifica esse resultado.

Esse resultado é válido apenas para valores contínuos. A discretização introduzida para a implementação da função *umbilicity* modifica o comportamento dos resultados. Para valores muito altos de σ , o borramento produzido é muito grande e os erros de aproximação fazem com que a estrutura não seja mais detectada. E nesse caso, o fator multiplicativo na expressão (AII.39), que é uma função do contraste da estrutura procurada, se torna relevante para o resultado da operação. Pode-se supor, que para valores da função *umbilicity* abaixo de um determinado limiar em relação ao valor máximo da função, o ponto (0,0) não é detectado. Dependendo do valor do contraste a , a função resultante da expressão (AII.38) fornece valores distintos para esse limiar.

Se for considerada uma estrutura com contraste muito alto, de tal forma a eliminar o efeito do fator multiplicativo em (AII.39) e estabelecendo o limiar em 5% do valor máximo, encontra-se a seguinte condição:

$$\frac{R}{\sigma_1} > 0,15 \Rightarrow \sigma_1 < 6,6R \quad (\text{AII.42})$$

Portanto, para uma imagem com alto valor de contraste, o ponto central (0,0) da função é detectado pelo operador *umbilicity* no intervalo $0,36R < \sigma < 6,6R$.

Para valores mais baixos de contraste, o fator multiplicativo modifica o resultado obtido na expressão (AII.42). Como a função é diretamente proporcional ao contraste, espera-se que à medida que o contraste diminua, o valor de σ para o qual a estrutura é detectada também deva diminuir.

Uma análise analítica e mais quantitativa da resposta do operador *umbilicity* em função do contraste não será realizada neste trabalho. Esta é, entretanto, uma linha de pesquisa interessante que será abordada em trabalhos futuros.

Teste qualitativo

Para verificação dos resultados obtidos neste item foram gerada três imagem de 256 x 256 pixels, com uma estrutura uniforme no centro, com raio igual a 1,5 pixel. As amplitudes geradas foram 1000, 800 e 200 contagens. As três imagens foram classificadas como alto contraste, médio contraste e baixo contraste.

Os resultados obtidos para as três imagens é obtido na tabela AII.3.

Tabela AII.3. Valores de σ para os quais o objeto de raio $R = 1.5$ sobrevive, para três níveis de contraste diferentes.

	baixo contraste	médio contraste	alto contraste
σ última escala detectada	2,34	3,28	9,16
σ primeira escala não detectada	2,77	3,89	10,8

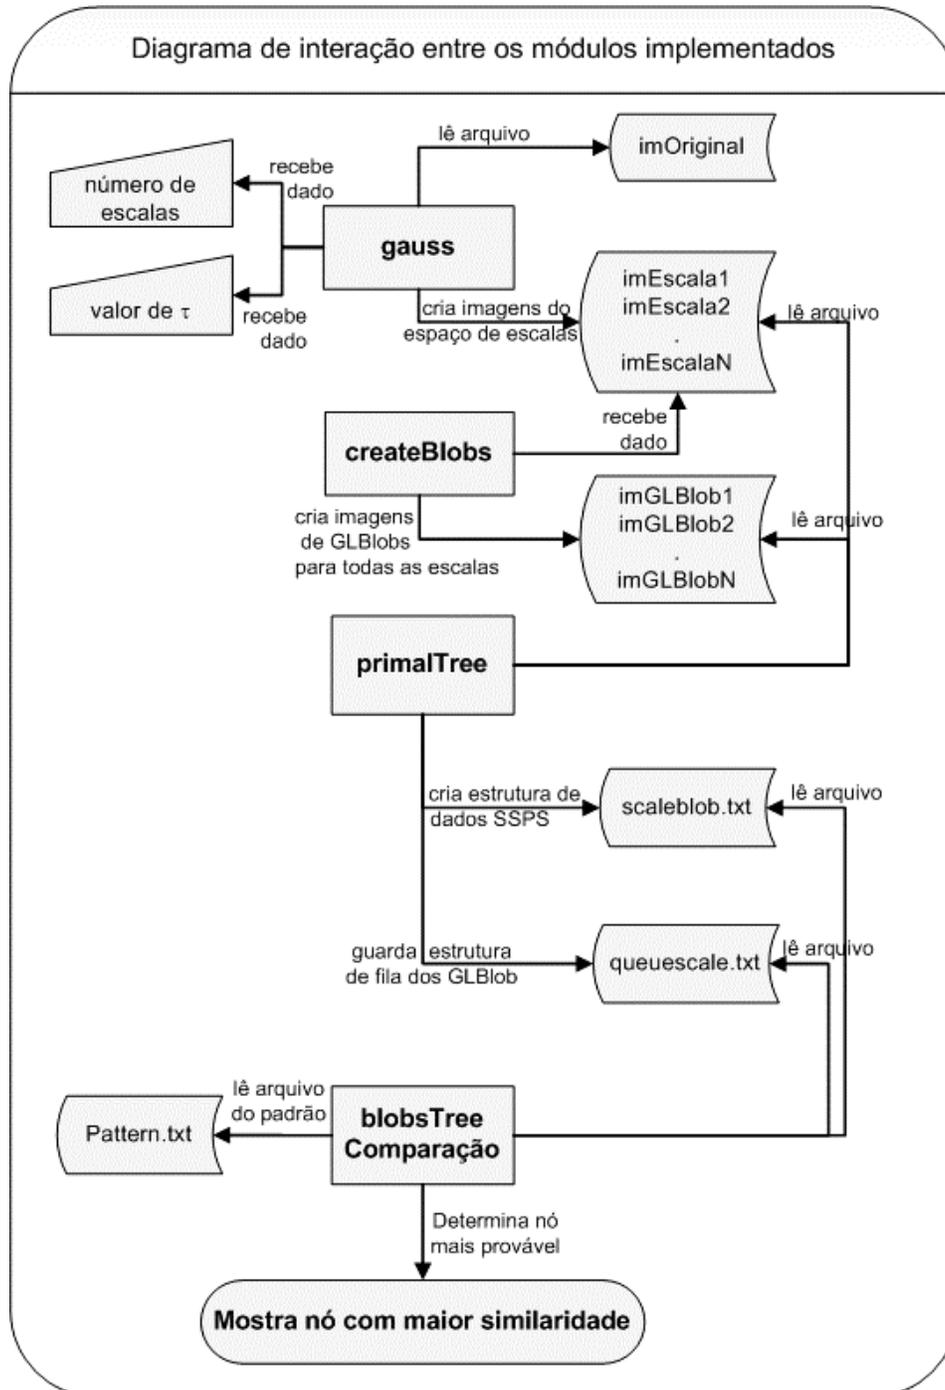
De acordo com o resultado obtido em AII.42 o objeto da imagem com alto contraste deve ser detectado, pela utilização do operador *umbilicity*, até a escala caracterizada por:

$$\sigma < 6,6R = 6,6 * 1,5 = 9,9 \text{ pixels}$$

O resultado obtido na imagem de alto contraste se mostra compatível com a previsão teórica. Observa-se, ainda, que à medida que o contraste diminui, o valor de σ de sobrevivência do objeto diminui.

Apêndice III

Interação entre os módulos



Apêndice IV

Análise da influência de τ

Neste apêndice, será feita uma análise qualitativa da influência do parâmetro τ na construção do espaço de escalas e do SSPS. A análise foi feita para duas imagens, uma imagem de simulação que contém dois círculos e um corte do *phantom* MCAT, para as quais foram construídos espaços de escalas utilizando diferentes valores de τ .

Caso 1. Imagem de simulação com dois círculos

Pretendia-se analisar o comportamento dos SSBlobs, em função do parâmetro τ , em uma imagem com estruturas simples. Para isso, criou-se a imagem apresentada na figura AIV.1. A figura tem resolução de 64 x 64 pixels e contém duas estruturas circulares. Na imagem original, sem ruído, a intensidade dos pixels do fundo era 10 e a dos pixels internos às estruturas era 200. A essa imagem foi adicionado ruído gaussiano aditivo (20 db). O diâmetro das duas estruturas é 7 pixels e a distância entre os seus centros geométricos, 14 pixels.

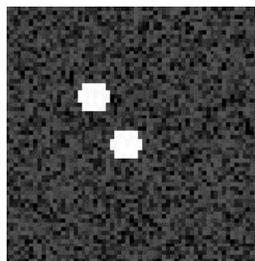


Figura AIV.1. Imagem simulada, com resolução de 64 x 64 pixels, formada por um fundo uniforme e duas estruturas circulares.

Os espaços de escala foram construídos, de acordo com a expressão 3.7, para uma faixa de valores de τ entre 0,10 a 0,24 com intervalos de 0,01. Os GLBlobs detectados em cada nível dos espaços de escala são mostrados na figura AIV.2.

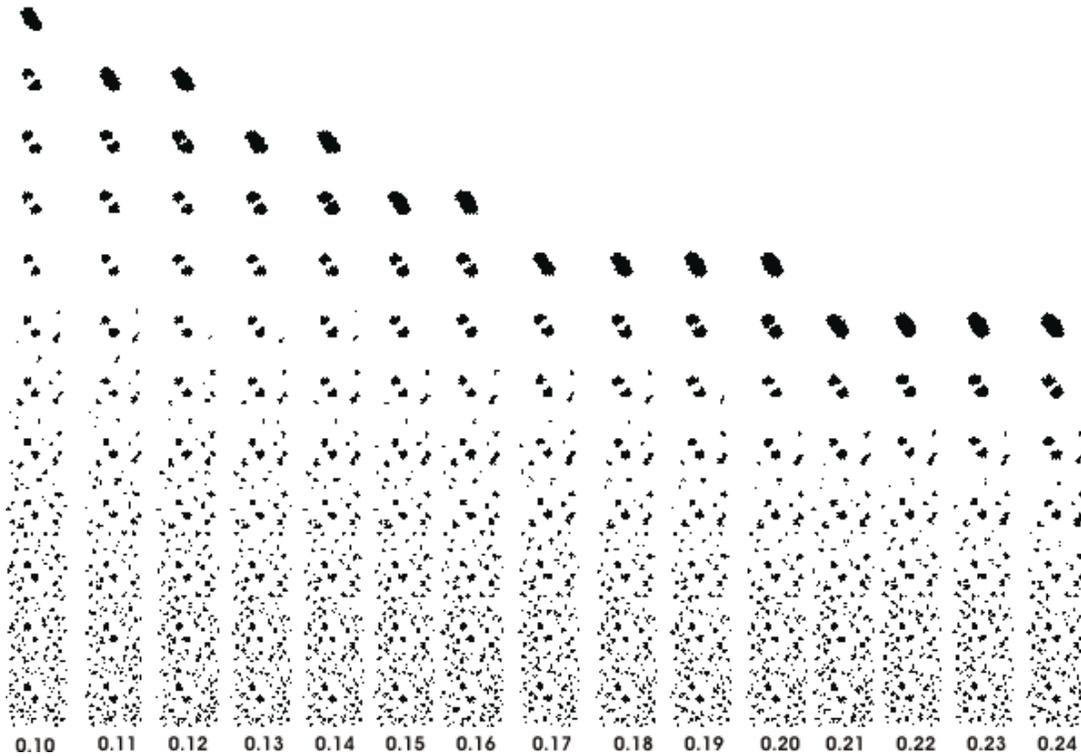


Figura AIV.2. Espaços de escala construídos com diferentes valores de τ , para a imagem mostrada em AIV.1.

Dois características desejadas para a aplicação do método proposto são: *(i)* o tempo de vida dos SSBlobs que representam as estruturas reais deve ser o maior possível, em relação ao tempo de vida total representado no SSPS, de tal forma que o parâmetro volume de SSBlob seja o mais significativo possível; *(ii)* devem existir níveis nos quais apenas os GLBlobs que representam as duas estruturas sejam detectados, para otimização da segunda fase de casamento.

Para a imagem simples mostrada na figura AIV.1, as duas características são satisfeitas para todos os valores de τ . Os SSBlobs correspondentes às duas estruturas sobrevivem desde o primeiro até o penúltimo nível de escala. Os espaços de escala com

valores mais baixos de τ apresentam um número excessivamente alto de níveis, o que eleva desnecessariamente o tempo de processamento, pois o maior número de escalas, neste caso, não acrescenta informação relevante para o processamento. Seria, então, possível utilizar os valores mais altos de τ , o que diminuiria o tempo de processamento, sem perda das características desejadas.

Caso 2. Imagem do *phantom* MCAT

A segunda imagem utilizada na análise foi um corte do *phantom* MCAT, com resolução de 64 x 64 pixels, mostrado em cores na figura 5.2, e que é visualizado em tons de cinza na figura AIV.3.

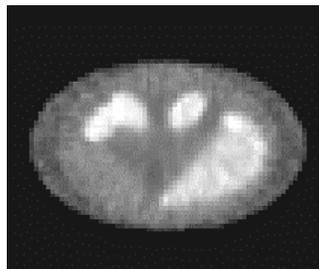


Figura AIV.3. Visualização em níveis de cinza do corte do *phantom* MCAT apresentado na figura 5.2.

Os espaços de escala foram construídos de acordo com a expressão 3.7, para uma faixa de valores de τ entre 0,13 a 0,23 com intervalos de 0,02. Os GLBlobs detectados em cada nível dos espaços de escala são mostrados na figura AIV.4.

Observa-se que para esta imagem, que contempla objetos mais complexos, os níveis inferiores contém diversos blobs que representam partes desconexas das estruturas reais, causado pelo ruído presente na imagem. Esse fato é relevante quando se analisam as características desejadas, descritas no item anterior. Percebe-se que, para valores de τ muito baixos, existem muitos níveis inferiores do espaço de escala que não contribuem com informações dos SSBlobs que representam os objetos reais da imagem. Para valores muito altos, a suavização mais acentuada faz com que as duas estruturas menores se acoplem muito rapidamente, diminuindo o tempo de vida dos SSBlobs que a representam. Na análise

visual das escalas, os valores intermediários de τ se mostram mais adequados. A análise de tempo de vida das estruturas em relação ao tempo total do SSPS mostra que o espaço de escala construído com $\tau = 0,19$ apresenta resultados mais satisfatórios para as duas estruturas menores.



Figura AIV.4. Espaços de escala construídos com diferentes valores de τ , para a imagem mostrada em AIV.3.

Deve-se observar que o valor do parâmetro a ser utilizado depende da resolução da imagem original, da dimensão e geometria das estruturas avaliadas e do contexto da imagem, ou seja a presença de outras estruturas. Conforme discutido no capítulo 3, o parâmetro τ está relacionado ao espaçamento entre os níveis. Assim, para analisar uma imagem mais complexa, em termos de número e forma dos objetos que a compõem, é necessário haver um menor espaçamento entre os níveis. Caso contrário, detalhes poderão ser perdidos na análise. Nos dois exemplos apresentados neste apêndice pôde-se verificar que o aumento da complexidade da imagem restringiu os valores mais adequados de τ para aplicação do método.

Referências Bibliográficas

- Alvarez, L., Lions, P.L., Morel, M., 1992. Image selective smoothing and edge detection by nonlinear diffusion. In: *SIAM Journal of Numerical Analysis*, 29(3), 845-866.
- Babaud, J., Witkin, A.P., Baudin, M., Duda, R.O., 1986. Uniqueness of the Gaussian kernel for scale space filtering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8, 26-33.
- Ballard, D.H., Brown, C.M., 1982. *Computer Vision*. Englewood Cliffs: Prentice-Hall, Inc.
- Bartolini, F., Carfagni, M., Governi, L., 2004. Model-based extraction of femoral medulla ducts from radiographic images. *Image and Vision Computing*, 22, 173-182.
- Bertero, M., Poggio, T.A., Torre, V., 1988. Ill-Posed Problems in Early Vision. *Proc. IEEE*, 76(8), 869-889.
- Black, M.J., Sapiro, G., Marimont, D.H., Heeger, D., 1998. Robust Anisotropic Diffusion. *IEEE Transactions on Image Processing*, 7(3), 421-432.
- Catté, F., Lions, P.L., Morel, J.M., Coll, T., 1992. Image selective smoothing and edge detection by nonlinear diffusion. *SIAM Journal of Numerical Analysis*, 29(1), 182-193.
- Chalopin, C., Magnin, I.E., Finet, G., 1998. Automatic labeling of the coronary tree using a three dimensional reference prior model. *Computers in Cardiology*, 25, 761-764.
- Cheng, H.D., Cai, X., Chen, X., Hu, L., Lou, X., 2003. Computer-aided detection and classification of microcalcifications in mammograms: a survey. *Pattern Recognition*, 36, 2967-2991.
- Cocosco, C.A., Zijdenbos, A.P., Evans, A.C., 2003. A fully automatic and robust brain MRI tissue classification method. *Medical Image Analysis*, 7, 513-527.
- Costa, M.G.F. e Moura, L., 1996. *Deteção e classificação automáticas de lesões em cintilografias de mama com MIBI^{99m}-Tc usando um filtro de novidade*. Tese (Doutorado). Universidade Estadual de Campinas.
- Coulon, O., Bloch, I., Frouin, V., Mangin, J.F., 1997. Multiscale measures in linear scale space for characterizing cerebral functional activations in 3D PET difference images. In: Ter Haar Romeny, B., Florack, L., Koenderink, J., Viergever, M. (Eds) *Lecture notes in computer science - Scale-space theory in computer vision 1252*. Berlin Heidelberg, Springer-Verlag, 188-199.
- Del Bimbo, A., Pala, P., 1999. Shape indexing by multi-scale representation. *Image and Vision Computing*, 17, 245-261.
- Deriche, R., 1993. Recursively implementing the Gaussian and its derivatives. *Rapports de Recherche, INRIA. Programme 4 Robotique, image et vision*.
- Dy, J.G., Brodley, C.E., Kak, A., Broderick, L.S., Aisen, A.M., 2003. Unsupervised feature selection applied to content-based retrieval of lung images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 25(3), 373-378.

- Elder, J.H., Zucker, S.W., 1998. Local Scale Control for Edge Detection and Blur Estimation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20, 699-716.
- Fang, B., Hsu, W., Lee, M.L., 2002. Tumor cell identification using feature rules. *Proceedings of 8th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 8th, 2002, Edmonton, Alberta, Canada*. ACM SIGKDD, 495-500.
- Fidrich, M., Thirion, J.P., 1994. Multiscale Extraction and Representation of Features from Medical Images. *Rapports de Recherche, INRIA. Programme 4 Robotique, image et vision*.
- Florack, L.M.J., ter Haar Romeny, B.M., Koenderink, J.J., Viergever, M.A., 1992. Scale and the differential structure of images. *Image and Vision Computing*, 10(6), 376-388.
- Florack, L.M.J., ter Haar Romeny, B.M., Koenderink, J.J., Viergever, M.A. 1994. Linear scale space. *Journal of Mathematical Imaging and Vision*, 4(4), 325-351.
- Florack, L.M.J., Salde, A.H., ter Haar Romeny, B.M., Koenderink, J.J., Viergever, M.A., 1995. Non linear scale space. *Image and Vision Computing*, 13(4), 279-294.
- Frangi, A.F., Niessen, W.J., Hoogeveen, R.M., Van Walsum, T., Viergever, M.A., 1999. Model-based quantitation of 3-D magnetic resonance angiographic images. *IEEE Transactions on Medical Imaging*, 18(10), 946-956.
- Fridman, J., Pizer, S. M., Aylward, S. Bullitt, E., 2004. Extracting branching tubular object geometry via cores. *Medical Image Analysis*, 8(3), 169-176.
- Gauch, J.M., Pizer, S.M., 1998. Image description via the multiresolution intensity axis of symmetry. *Proceedings of 2nd Int. Conf. Computer Vision*, 269-274.
- Gauch, J.M., 1999. Image Segmentation and Analysis via Multiscale Gradient Watershed Hierarchies. *IEEE Transactions on Image Processing*, 8(1), 69-79.
- Gerig, G., Kubler, O, Kikinis, R., Jolesz, F. A., 1992. Nonlinear anisotropic filtering of MRI data. *IEEE Transactions on Medical Imaging*, 11, 221-232.
- Godtliebsen, F. , Marron, J.S. Chaudhuri, P., 2004. Statistical significance of features in digital images. *Image and Vision Computing*, 22, 1093-1104.
- Gonzales, R., Woods, R.E., 2000. *Processamento de imagens digitais*. São Paulo: Editora Edgard Blücher Ltda.
- Goodenday, L.S., Cios, K.J., Shin, I., 1997. Identifying coronary stenosis using an image-recognition neural network. *IEEE Engineering in Medicine and Biology*, 16(5), 139-144.
- Gregory, R., 1990. How do we interpret images? *In: Barlow, H., Blakemore, C., Weston-Smith, M. Images and Understanding*. New York: Cambridge University Press. Cap.20, p. 310-330.
- Griffin, L., Colchester, A.C.F., 1995. Superficial and deep structure in linear diffusion scale space: isophotes, critical points and separatrices. *Image and Vision Computing*, 13(7), 543-557.

- Gutierrez, M.A., Rebelo, M.S., Furuie, S.S., Moura, L., Avila, L., Parga, J.R., 1997a. Myocardial Motion Estimation in Gated-MRI Using Optical Flow Refined with Scale Space. *Computers in Cardiology*, 24,153-156.
- Gutierrez, M.A., Rebelo, M.S., Furuie, S.S., Moura, L., Meneghetti, J.C., 1997b. The Assessment of Myocardial Motion Combining Optical Flow and Scale Space Approaches. *Medical & Biological Engineering & Computing*, 35(2), 729.
- Gutierrez, M.A., Rebelo, M.S., Cattani, C., Sauerbeck, H.P., Furuie, S.S., 1998a. Quantitative myocardial kinetic energy as a physiological parameter in cine-MRI. *Proc. of the 20th International Conference of the IEEE Engineering in Medicine and Biology Society*, 488-491.
- Gutierrez, M.A., Rebelo, M.S., Furuie, S.S., 1998b. A multiresolution method to computing myocardial motion. *Proc. of IEEE International Conference on Time-frequency & Time-scale Analysis*, 89-92.
- Gutierrez, M.A., Rebelo, M.S., Furuie, S.S., 2003. Automatic quantification of three-dimensional kinetic energy in gated myocardial perfusion single-photon-emission computerized tomography improved by a multiresolution technique. *Journal of Electronic Imaging*, 12(1), 118-124.
- Gutierrez, M.A., Furuie, S.S., Rebelo, M.S., Meneghetti, J.C., 2004. Automatic methods to analyze and quantify cardiac left ventricle parameters by means of SPECT. In: Leondes, C.T. (Org.). *Medical Imaging Systems Technology: Methods in Cardiovascular and Brain Systems*, 5, 61-88.
- Gutierrez, M.A., Furuie, S.S., Rebelo, M.S., Meneghetti, J.C., 2005. Automatic methods to analyze and quantify left ventricle parameters by means of SPECT. In: Leondes, C. (Editor). *International Volumes on Medical Imaging Systems*. World Scientific Publishing CO. (no prelo).
- Jackway, P.T., Deriche, M., 1996. Scale-space properties of the multiscale morphological dilation-erosion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18(1), 38-51.
- Karam, H., Hamad, A.M., Ghiniemy, S., Rady, S., 2003. Enhancement of wavelet-based medical image retrieval through feature evaluation using an information gain measure. *Proceedings of the 2003 ACM symposium on Applied computing*, 220-226.
- Keserci, B., Yoshida, H., 2002. Computerized detection of pulmonary nodules in chest radiographs based on morphological features and wavelet snake model. *Medical Image Analysis*, 6, 431-447.
- Keshet, R., Heijmans, H.J.A.M., 2003. Adjunctions in Pyramids, Curve Evolution and Scale-Spaces. *International Journal of Computer Vision*, 52(2/3), 139-151.
- Kim, K.S., Kim, P.K., Song, J.J., Park, Y.C., 2000. Analyzing Blood Cell Image to Distinguish Its Abnormalities. *Proceedings of the 8th ACM International Conference on Multimedia Table of Contents*, 395-397.
- Kimia, B.B., Tannenbaum, A., Zucker, S.W., 1994. Shapes, shocks and deformations. *International Journal of Computer Vision*, 15(3), 189-224.

- Kimmel, R., 1997. Intrinsic scale space for images on surfaces: the geodesic curvature flow. In: ter Haar Romeny, B.M., Florack, L., Koenderink, J.J., Viergever, M.A. (Editors). *Lecture notes in computer science - Scale-space theory in computer vision 1252*. Berlin Heidelberg: Springer-Verlag, 212-223.
- Kobashi, M., Shapiro, L.G., 1995. Knowledge-based organ identification from CT images. *Pattern Recognition*, 27(4), 475-491.
- Koenderink, J.J., 1984. The structure of images. *Biological Cybernetics*, 50, 363-370.
- Koenderink, J.J., van Doorn, A.J., 1990. Receptive field families. *Biological Cybernetics*, 63, 291-291.
- Koenderink, J.J., van Doorn, A.J., 1992. Generic neighborhood operators. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14(6), 597-605.
- Krissian, K., Malandain, G., Ayache, N., Vaillant, R., Troussset, Y., 2000. Model Based Detection of Tubular Structures in 3D Images. *Computer Vision and Image Understanding*, 80(2), 130-171.
- Kunz, H., Derz, C., Tolxdorff, T., Bernarding, J., 2004. Feature extraction and supervised classification of MR images to support proton radiation therapy of eye tumors. *Computer Methods and Programs in Biomedicine*, 73, 195-202.
- Lei, B.J., Hendriks, E.A., Reinders, M.J.T., 1999. On Feature Extraction from Images. *Technical report on "inventory properties" for MCCWS Project Information and Communication Theory Group TU, Delft*.
- Lifshitz, L.M., Pizer, S.M., 1990. A Multiresolution Hierarchical Approach to Image Segmentation Based on Intensity Extrema. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(6), 529-540.
- Lillholm, M., Nielsen, M., Griffin, L.D., 2003. Feature-Based Image Analysis. *International Journal of Computer Vision*, 52(2/3), 73-95.
- Lin, N., Yu, W., Duncan, J.S., 2003. Combinative multi-scale level set framework for echocardiographic image segmentation. *Medical Image Analysis*, 7, 529-537.
- Lindeberg, T., 1990. Scale space for discrete signals. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(3), 234-254.
- Lindeberg, T., 1993. Detecting Salient Blob-like image structures and their scales with a scale-space primal sketch: a method for focus of attention. *International Journal of Computer Vision*, 11(3), 283-318.
- Lindeberg, T., 1994. Scale-space theory: a basic tool for analyzing structures at different scales. *Journal of Applied Statistics*, 21(2), 225-270.
- Lindeberg, T., 1998. Edge detection and ridge detection with automatic scale selection. *International Journal of Computer Vision*, 30(2), 117-154.
- Liu, S., Babbs, C.F., Delp, E.J., 2001. Multiresolution detection of spiculated lesions in digital mammograms. *IEEE Transactions on Image Processing*, 10(6), 874-884.
- Llacer, J., ter Haar Romeny, B.M., Florack, L., Viergever, M.A., 1993. Representation of medical images by visual response functions. *IEEE Engineering in Medicine and Biology*, 12(1), 40-47.

- Majer, P., 2000. *A Statistical Approach to Feature Detection and Scale Selection in Images*. Tese (Doutorado). Universidade de Göttingen, Alemanha.
- Marr, D., Hildreth, E., 1980. Theory of edge detection. *Proc. R. Soc. Lond. B* 207, 187-207.
- Netsch, T., Peitgen, H.O., 1999. Scale-Space Signatures for the Detection of Clustered Microcalcifications in Digital Mammograms. *IEEE Transactions on Medical Imaging*, 18(9), 774-786.
- Nevatia, R., 1982. *Machine Perception*. Prentice-Hall.
- Nielsen, M., Florack, L., Deriche, R., 1994. Regularization and scale space. *Rapports de Recherche, INRIA. Programme 4 Robotique, image et vision*.
- Niessen, W., Duncan, J.S., Florack, L.M.J., ter Haar Romeny, B.M., Viergever, M.A., 1995. Spatiotemporal operators and optic flow. In: Huang, S.T., Mataxas, D.N. (Editors). *Physics-based modeling in computer vision*. IEEE Computer Society Press, 78-84.
- Niessen, W., 1997. *Medical Image Analysis*. Tese (Doutorado). Universidade de Utrecht, Holanda.
- Nitzberg, M., Shiota, T., 1992. Nonlinear image filtering with edge and corner enhancement. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14, 826-833.
- Ogiela, M., Tadeusiewicz, R., 2000. Syntactic pattern recognition for X-ray diagnosis of pancreatic cancer. *IEEE Engineering in Medicine and Biology*, 19(6), 94-105.
- Park, M., Wilson, L.S., Jin, J., 2000. Automatic Extraction of Lung Boundaries by a Knowledge-Based Method. *ACM International Conference Proceeding Series archive Selected papers from the Pan-Sydney workshop on Visualisation*, 2, 11-16.
- Pauly, M., Keiser, R., Gross, M., 2003. Multi-scale Feature Extraction on Point-sampled Surfaces. *EUROGRAPHICS 2003*, 22(3).
- Perona, P., Malik, J., 1990. Scale-space and edge detection using anisotropic diffusion. *IEEE Transactions on Pattern Analysis*, 12(7), 629-639.
- Pizer, S.M., Burbeck, C.A., Coggins, J.M., Fritsh, D.S., Morse, B.S., 1994. Object shape before boundary shape: scale space medial axes. *Journal of Mathematical Imaging and Vision*, 4(3), 303-313.
- Rangayan, R.M., 2005. *Biomedical Image Analysis*. Boca Raton, Florida: ©CRC Press.
- Rebelo, M.S., Gutierrez, M.A., Furuie, S.S., Moura, L., 1998. Multiscale Method to isolate cardiac structures in MRI. *Computers In Cardiology*, 25, 501-504.
- Rebelo, M.S., Gutierrez, M.A., Furuie, S.S., Moura, L., 2000. Extraction of cardiac structures through the incorporation of a priori knowledge in a multi-scale approach. *Computers in Cardiology*, 27, 611-614.
- Rivière, D., Mangin, J.F., Papadopoulos-Orfanos, D., Martinez, J.M., Frouin, V., Régis, J., 2002. Automatic recognition of cortical sulci of the human brain using a congregation of neural networks. *Medical Image Analysis*, 6, 77-92.
- Ruggeri, A., Pajaro, S., 2002. Automatic recognition of cell layers in corneal confocal microscopy images. *Computer Methods and Programs in Biomedicine*, 68, 25-35.

- Spiegel, M.R., 1973. *Manual de fórmulas e tabelas matemáticas. Coleção Shown*. São Paulo: McGraw-Hill.
- Smith, J.R., Lin, C.Y., Naphade, M., Natsev, A.P., Tseng, B., 2003. Statistical Techniques for Video Analysis and Searching. In: Rosenfeld, A., Doermann, D., DeMenthon, D. (Editors). *Video mining*. Boston/Dordrecht/London: Kluwer Academic Publishers, The Kluwer International Series in Video Computing. Capítulo 9, 252-277.
- Sonka, M., Hlavac, V., Boyle, R., 1998. *Image processing, analysis, and machine vision*. 2ª edição, Pacific Grove: Brooks/Cole Publishing Company.
- Suetens, P., Fua, P., Hanson, A.J., 1992. Computational strategies for object recognition. *ACM Computing Surveys*, 24(1), 5-55.
- Ter Haar Romeny, B.M., 1996. Introduction to scale-space theory. *Tutorial of Fourth International Conference on Visualization in Biomedical Computing*.
- Thies, C., Metzler, V., Lehmann, T., Aach, T., 2004. Formal extraction of biomedical objects by subgraph matching in attributed hierarchical region adjacency graphs. *Medical Imaging 5370*, 14-19.
- UNC – Medical Imaging research Laboratory. *The Mathematical Cardiac Torso (MCAT) Phantom*. Disponível em: <http://www.bme.unc.edu/mirg/mcat/> [acesso em 31 jan. 2005].
- van den Boomgaard, R., Smeulders, A.W.M., 1994. The morphological structure of images, the differential equations of morphological scale-space. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 16(11), 1101-1113.
- van Ginneken, B., Romeny, B.M.T.H., Viergever, M.A., 2001. Computer aided diagnosis in chest radiography: a survey. *IEEE Transactions on Medical Imaging*, 20(12), 1228-1241.
- Verma, B., Zakos, J., 2001. A computer-aided diagnosis system for digital mammograms based on fuzzy-neural and feature extraction techniques. *IEEE Transactions on Information Technology in Biomedicine*, 5(1), 46-54.
- Vilanova, A., Gröller, E., König, A., 2000. A cylindrical approximation of tubular organs for virtual endoscopy. *Computer Graphics and Imaging 2000, Conference Proceedings*, IASTED/ACTA Press, 283-289.
- Vinken, K., 1995. *Probabilistic Multiscale Image Segmentation by yhe Hyperstack*. Tese (Doutorado). Universidade de Utrecht, Holanda.
- Weickert, J., 1997. Recursive separable schemes for nonlinear diffusion filters. In: ter Haar Romeny, B.; Florack, L.; Koenderink, J.; Viergever, M. (Editors.). *Lecture notes in computer science - Scale-space theory in computer vision*. 1252. Berlin Heidelberg: Springer-Verlag, 260-271.
- Weickert, J., 1997. Image smoothing and restoration by PDEs. In: Weickert, J. *Anisotropic diffusion in image processing*. Stuttgart: Teubner, capítulo 1, 1-53.
- Witkin, A.P., 1983. Scale space filtering. In: *8th IJCAI*, 1019-1022.

- You, Y.L., Xu, W., Tannenbaum, A., Kaveh, M., 1996. Behavioral analysis of anisotropic diffusion in image processing. *IEEE Transactions on Image Processing*, 5, 1539–1553.
- Yuille, A.L., Poggio, T.A., 1986. Scaling theorems for zero-crossings. *IEEE-PAMI*, 8, 15-25.
- Zrimec, T., Sammut, C., 1997. A medical image-understanding system. *Engineering Applications of Artificial Intelligence*, 10(1), 31-39.
- Zwiggelaar, R., Parr, T.C., Schumm, J.E. , Hutt, I.W., Taylor, C.J., Astley S.M., Boggis, C.R.M., 1999. Model-based detection of spiculated lesions in mammograms. *Medical Image Analysis*, 3(1), 39-62.