

UNIVERSIDADE FEDERAL DE PELOTAS

Bacharelado em Ciência da Computação
Instituto de Física e Matemática
Departamento de Informática



Trabalho Acadêmico

Segmentação Semiautomática do Volume Encefálico Global
em Exames de Ressonância Magnética
Através da Técnica de Watershed

João Alberto Vortmann

Pelotas, 2008

JOÃO ALBERTO VORTMANN

**Segmentação Semiautomática do
Volume Encefálico Global em Exames
de Ressonância Magnética Através da
Técnica de Watershed**

Trabalho acadêmico apresentado ao
Bacharelado em Ciência da Computação
da Universidade Federal de Pelotas, como
requisito parcial para a obtenção do grau de
Bacharel em Ciência da Computação

Orientador: Prof. Dr. Lucas Ferrari de
Oliveira

Pelotas, 2009

Dados de catalogação na fonte:
Maria Beatriz Vaghetti Vieira – CRB-10/1032
Biblioteca de Ciência & Tecnologia - UFPel

V957s Vortmann, João Alberto

Segmentação semiautomática do volume encefálico global em exames de ressonância magnética através da técnica de Watershed / João Alberto Vortmann ; orientador Lucas Ferrari de Oliveira. – Pelotas, 2008. – 73f. - Monografia (Conclusão de curso). Curso de Bacharelado em Ciência da Computação. Departamento de Informática. Instituto de Física e Matemática. Universidade Federal de Pelotas. Pelotas, 2008.

1.Informática. 2.Segmentação semiautomática. 3. Ressonância magnética. 4. Watershed. 5. Auxílio ao diagnóstico. I.Oliveira, Lucas Ferrari de II.Título.

CDD: 006.6

*"I do not fear computers.
I fear the lack of them."*
— ISAAC ASIMOV

"Men are equal; it is not birth but virtue that makes the difference."
— FRANCOIS MARIE AROUET - VOLTAIRE

"If I have seen further it is by standing on the shoulders of giants."
— ISAAC NEWTON

*"I may not have gone where I intended to go,
but I think I have ended up where I needed to be."*
— DOUGLAS ADAMS

AGRADECIMENTOS

Agradeço primeiramente aos meus pais, Jorge Alberto e Marcelaine Vortmann, pelo exemplo que são de dedicação e trabalho. Vosso apoio durante essa etapa foi fundamental! Não seríamos quem somos sem a educação que vocês nos proporcionaram. Mas sobretudo foi vosso amor que nos manteve firme, de cabeça erguida e com o olhar no futuro. Me orgulho de vocês! Amo vocês! Agradeço pelo apoio também os meus tios e tias, Carlos e Rita, Marco e Margot, e tio Cezar; os primos e primas, Renato, Luiza e Priscila; e os avôs e avós, Alberto e Elaine e Albino e Clary.

Gostaria de agradecer ao meu amor, Luciele. Teu grande amor me tornou uma pessoa melhor. Apesar da distância, tu me apoiaste sempre e te admiro por isso. Te admiro pela pessoa que és, pela garra e ânimo que tens. Tu és uma pessoa muito especial! Obrigado pela compreensão e pela paciência. Te amo muito! Muito! Agradeço à Levi e Vera pela amizade e pela filha maravilhosa!

Ao meu irmão. O que sinto por ti já diziam Kleiton e Kledir:

Quando eu era assim
Bem menor
Não tive afim, sei lá
De pensar em nós
Agora eu sei e entendo melhor
Vidente eu li no céu
Vai por mim, somos corpo e alma
Meu irmão, meu par

Agradeço os professores que tive o prazer de conviver. Em especial aos Professores José Luís Almada Güntzel, Luciano Volcan Agostini e Lucas Ferrari de Oliveira. Agradeço-os pela ética e dedicação à profissão. Aos Professores Güntzel e Luciano agradeço pela oportunidade com iniciação científica, experiência que, não só pelo aprendizado e pesquisa, mas principalmente pelas amizades, me fez crescer como pessoa. Ao Professor Lucas pela orientação e dedicação prestada. Além disso, a amizade de vocês é muito importante para

mim. Obrigado!

Gostaria de agradecer também aos Professores Gil Carlos R. Medeiros e Eliane Alcoforado Diniz pela força e dedicação que se empenham. Obrigado pelo desenvolvimento e oportunidades que lutam pra proporcionar ao curso! Espero que esse crescimento seja contínuo e que os todos professores do curso se dediquem ao máximo pela educação ética e de qualidade acima de tudo.

Gostaria de agradecer especialmente ao amigo Joel Pinho Lucas. Tua amizade desde os tempos de faculdade significa muito para mim. Pode contar sempre comigo! (e sei que a recíproca é verdadeira). Sei que mesmo o Atlântico não é capaz de interferir em uma amizade quando ela é verdadeira! Muito Obrigado! Obrigado pela amizade, pelas traduções, pelas dicas, por tudo! Valeu também por me apresentar o Velho Mundo! Foi a viagem mais divertida que já fiz! Abração!

Aos meus colegas de turma (mesmo os que não seguiram no curso), que nos acompanharam durante noites estudando cálculo ou programando. Agradeço pela amizade, pelo companheirismo e pela hospitalidade. As jantãs e jogos de futebol da turma foram apenas um exemplo dos bons momentos que passamos juntos! Espero manter vossa amizade indefinidamente! Obrigado Carlo, Roberto, Quevedo, Peterson, Carol, Castañeda, Roger, Paulo Tiago, Vitor, Gabriel, Fabiane, Fábio, Piero, Eduardo, Marcelo, Douglas, Bianca . . .

Agradeço também aos colegas de curso e do GACI, de todas as "gerações", pela amizade, as conversas agradáveis e divertidas regadas a café (de preferência bem forte). Agradeço pela amizade! E continuem com essa vontade de trabalhar, bom humor e otimismo que é o que nosso mundo precisa! Valeu Matheus, Leandro, Thaísa, Guilherme, Felipe, Eduardo, Duda, Daniel, Diego, Carol, Bruno, Elvio, Adriano, Rafael, Filipe, Beatriz, Gustavo . . .

Agradeço também aos meus amigos. Pela amizade que se manteve após o colégio, pelos churrascos de última hora e as conversas interessantes. Obrigado Ítalo, Pitter, Francis(s), Lucas, Marcelo, Tiago, Alexandre, Eduardo(s), Tatiele, Rita, Racieli, Tammi, Gabriel . . . Dos amigos que fizemos em Pelotas, agradeço em especial à Martín Chagas, Rodrigo Chagas e família. Vocês tornaram a estada em Pelotas mais encantadora! Mais pessoas deveriam ter o respeito pelo próximo como vocês! Obrigado! Agradeço em especial à Bruno e Pedro Lucas e Felipe Augusto Lopes pela incrível e inesquecível viagem e pela amizade e parceria! Gracias!

Às pessoas que de alguma forma contribuíram para a minha formação e que porventura não explicitarei. As madrugadas imersas no trabalho de conclusão podem ter me afetado a memória. Abraço!

RESUMO

Vortmann, João Alberto. **Segmentação Semiautomática do Volume Encefálico Global em Exames de Ressonância Magnética Através da Técnica de Watershed**. 2009. 73 f. Monografia (Bacharelado em Ciência da Computação). Universidade Federal de Pelotas, Pelotas.

O processo de diagnóstico através de imagens anatômicas é um processo laborioso e cansativo. Este processo é realizado através da visualização, pelo especialista, de cortes do objeto em estudo. Um exame de ressonância magnética geralmente é constituído de 60 a 120 cortes. A identificação de alguma patologia cerebral toma muito tempo do especialista. Visando auxiliar no processo quantitativo de diagnóstico, foi desenvolvida uma ferramenta capaz de detectar automaticamente o volume cerebral e demarcá-lo. Assim, em minutos, o especialista é capaz de fazer uma avaliação das regiões que lhe interessam no exame. A ferramenta é capaz de ler imagens DICOM de ressonância magnética de encéfalo, aplicar filtros para o realce de elementos relevantes (como bordas) e identificar o volume encefálico global através da aplicação da técnica de *watershed*. O volume identificado pela ferramenta foi analisado através de um ferramenta auxiliar e os resultados são apresentados. Os resultados demonstram a validade da técnica de *watershed* para a segmentação semiautomática do volume encefálico global além de servir de base para melhorias quanto à precisão e tempo de execução.

Palavras-chave: Segmentação Semiautomática, Ressonância Magnética, Watershed, Auxílio ao Diagnóstico.

ABSTRACT

Vortmann, João Alberto. **Semi-automatic Segmentation of Brain Volume in Magnetic Resonance Using Watershed**. 2009. 73 f. Monography. Universidade Federal de Pelotas, Pelotas.

The diagnosis procedure through anatomical images is laborious and tiring. The specialist perform this process by viewing slices from the studied object. The Magnetic Resonance Image (MRI) analysis commonly involves between 60 and 120 slices. The identification of some brain disease requires considerable amount of time of the specialist. Working toward this, the developed tool intend to aid this quantitative diagnosis process, detecting and labelling the brain volume in an semi-automatic manner. In this way, in minutes, the specialist can evaluate the regions of interest in the images. The tool is able to read DICOM MRI images, apply filters to enhance relevant elements (such as boundaries) and detect and label the brain volume using the watershed technique. The segmented volume has been analysed using an auxiliary tool and the results are shown. These results show the validity of watershed technique to semi-automatic segmentation of the brain volume, and furthermore, can be used as foundation to improvements in the tool's precision and time consuming.

Keywords: Semi-automatic Segmentation, Magnetic Resonance, Watershed, Aided Diagnosis.

LISTA DE FIGURAS

Figura 1	Aquisição de imagens utilizando fila de sensores	19
Figura 2	Amostragem e quantização	20
Figura 3	Representação volumétrica	20
Figura 4	Ressonância magnética	24
Figura 5	Ressonância magnética detalhada	25
Figura 6	Imagens de RM nos 3 planos.	26
Figura 7	Metodologias utilizadas no Processamento de Imagens	28
Figura 8	Imagem como matriz de pixels	29
Figura 9	Diferença entre imagens	31
Figura 10	Mascaramento	32
Figura 11	Operações lógicas	33
Figura 12	Transformação espacial	35
Figura 13	Filtro de suavização	37
Figura 14	Filtros de média e de mediana	37
Figura 15	Operadores de Sobel	39
Figura 16	Filtro de gradiente	40
Figura 17	Máscaras de <i>Laplace</i>	40
Figura 18	Filtro <i>Laplaciano</i>	40
Figura 19	Segmentação por limiarização	43
Figura 20	Segmentação por descontinuidade	44
Figura 21	Segmentação por detecção de bordas	44
Figura 22	Crescimento de regiões	46
Figura 23	Divisão e fusão	46
Figura 24	Segmentação por similaridade	47
Figura 25	Conceito de watershed	48
Figura 26	Barreiras entre fluxos distintos (<i>watershed lines</i>)	49
Figura 27	Execução do <i>watershed</i>	50
Figura 28	Filtro de borramento preservando bordas	55

Figura 29	Filtro de realce de bordas (gradiente)	55
Figura 30	Implementação do <i>watershed</i> no ITK	57
Figura 31	<i>Pipeline</i> de execução desenvolvido	59
Figura 32	Etapa 1 do <i>pipeline</i> de execução - borramento	60
Figura 33	Etapa 2 do <i>pipeline</i> de execução - realce de bordas	61
Figura 34	Etapa 3 do <i>pipeline</i> de execução - inversão da imagem	62
Figura 35	Etapa 4 do <i>pipeline</i> de execução - <i>watershed</i>	62
Figura 36	Resultado da ferramenta - cortes	63
Figura 37	Volume de entrada	64
Figura 38	Volume detectado	65

LISTA DE ABREVIATURAS E SIGLAS

2D	Bidimensional
3D	Tridimensional
ACR	<i>American College of Radiology</i>
DICOM	<i>Digital Imaging and Communications in Medicine</i> - Aquisição Digital de Imagens e Comunicações na Medicina
GNU	Acrônimo recursivo para <i>GNU is Not UNIX</i> - GNU não é UNIX.
HUG	<i>Hôpitaux Universitaires de Genève</i> - Hospital Universitário de Genebra
ITK	<i>National Library of Medicine Insight Segmentation and Registration Toolkit</i> – Conjunto de ferramentas para segmentação e registro de imagens da NLM
MCDE	<i>Modified Curvature Diffusion Equation</i> - equação modificada de borramento de curvatura
MN	Medicina Nuclear
MRI	Magnetic Resonance Imaging - Aquisição de Imagens por Ressonância Magnética
NEMA	<i>National Electrical Manufacturers Association</i>
NLM	<i>National Library of Medicine</i>
PET	<i>Positron Emission Tomography</i> – Tomografia por emissão de pósitrons
RF	Radiofrequência
RM	Ressonância Magnética
ROIs	<i>Regions of Interest</i> - Regiões de Interesse.
SPECT	<i>Single Photon Emission Computed Tomography</i> – Tomografia Computadorizada por Emissão de Fóton Único
TC	Tomografia Computadorizada

US Ultra-sonografia

SUMÁRIO

RESUMO	5
ABSTRACT	6
LISTA DE FIGURAS	7
LISTA DE ABREVIATURAS E SIGLAS	10
1 INTRODUÇÃO	13
1.1 Motivação	15
1.2 Objetivos	15
1.3 Organização do Trabalho	16
2 AQUISIÇÃO E VISUALIZAÇÃO DE IMAGENS	17
2.1 Conceitos	17
2.1.1 Aquisição	18
2.1.2 Visualização	19
2.2 Imagens na Medicina	21
2.2.1 Exames	21
2.2.2 Padrão DICOM	22
2.3 Ressonância Magnética	24
2.3.1 Princípio	24
2.3.2 Características	25
2.4 Síntese do Capítulo	26
3 PROCESSAMENTO DE IMAGENS	27
3.1 Visão Geral	27
3.2 Operações sobre Imagens	29
3.2.1 Operações Aritméticas	29
3.2.2 Operações Lógicas	32
3.3 Realce de Imagens	33

3.3.1	Filtros de Suavização	35
3.3.2	Filtros de Alta Freqüência	37
3.4	Segmentação de Imagens	39
3.4.1	Técnicas de Segmentação	41
3.4.2	Watershed	47
3.5	Síntese do Capítulo	50
4	FERRAMENTA DESENVOLVIDA	51
4.1	Materiais	51
4.1.1	Equipamento e Sistema Operacional	51
4.1.2	Linguagem de Desenvolvimento	52
4.1.3	Bibliotecas Gráficas	52
4.1.4	Filtros Utilizados	53
4.1.5	Imagens Utilizadas	58
4.2	Métodos	58
4.2.1	Considerações quanto ao problema	58
4.2.2	Pipeline de Processamento	58
5	RESULTADOS OBTIDOS	63
5.1	Simulações	63
5.2	Considerações	64
6	CONSIDERAÇÕES FINAIS	66
6.1	Conclusões	67
6.2	Trabalhos Futuros	68
	REFERÊNCIAS	69

1 INTRODUÇÃO

Existe um grande número de neuropatologias relacionadas à variação de volume de determinadas estruturas cerebrais, que podem ser observadas em vida através do diagnóstico por imagens anatômicas. O uso de imagens proporciona uma avaliação não invasiva dos tecidos e órgãos do corpo humano (FILHO, 1999 apud ZANCHET, 2007). A detecção e o tratamento de patologias neurológicas é feito principalmente através da análise de exames representados graficamente, como os exames de ressonância magnética (RM) e tomografia computadorizada (TC). Imagens de RM é a modalidade de imagens médicas anatômicas mais utilizada dada a sua alta definição e alto contraste.

A análise das imagens provenientes destes exames sem o auxílio de alguma ferramenta computadorizada é feita comparando-se, lado a lado, imagens impressas em filmes radiográficos que representam diferentes cortes do objeto analisado. Para auxiliar nesta análise, existem *softwares* proprietários que realizam diversas tarefas, tais como alinhamento, marcação de regiões de interesse (ROIs), tratamento de imagens e segmentação.

São diversos os fatores que influenciam no processo de diagnóstico. As relações intra e inter especialista afetam o processo na medida em que, da análise de diversos cortes diferentes de um mesmo exame, pode-se obter conclusões diferentes. Ademais, a marcação manual das regiões de interesse é um processo trabalhoso e cansativo, e que apresenta limitações quanto à reprodutibilidade dos estudos pois exige, por parte do especialista, conhecimentos prévios de neuroanatomia e destreza motora (MOREIRA, 2004 apud MILANI, 2007).

O primeiro passo para o entendimento de uma cena é sua partição, destacando as regiões representativas da imagem. Essa divisão pode ser feita a partir dos valores de tons de cinza (ou cores) da imagem, de texturas, de formas, entre outras.

A segmentação é um processo natural ao ser humano, mas não aos computadores. O cérebro humano é capaz de reconhecer objetos assim que

os vê, interpretando e combinando informações obtidas pelo sistema visual de modo paralelo. A visão só é possível através da interpretação das informações obtidas pelo sistema visual humano, como intensidade de luz e cor.

A segmentação é um estágio prévio de processamento para reconhecimento ou identificação das imagens (CONCI; AZEVEDO; LETA, 2008). O processo de segmentação é a divisão de uma imagem em regiões representativas no contexto de uma aplicação. O objetivo é agrupar e destacar os *pixels* dos objetos ou áreas de interesse. É considerada uma das tarefas mais difíceis em processamento de imagens digitais, como destacam Gonzalez e Woods (2008). Um processo de segmentação eficaz agiliza a obtenção de uma solução correta para problemas em processamento de imagens, enquanto que um processo errático ou fraco de segmentação é garantia de algum tipo de falha (GONZALEZ; WOODS, 2008). As principais abordagens para a segmentação são: limiarização, crescimento de regiões e divisão e fusão de regiões.

Existem dificuldades inerentes ao processo de segmentação automática de imagens. Deve-se considerar que as bordas ou limites das regiões podem não ser muito nítidas, sendo muitas vezes irregulares e imprecisas. Quando uma região é delimitada, os *pixels* pertencentes a uma mesma região são agrupados e podem ser demarcados com cores, por exemplo, indicando que pertencem à mesma estrutura (NUNES; CONCI, 2007).

Na segmentação através de *watershed* (GONZALEZ; WOODS, 2008; RUSS, 2007; PRATT, 2007), a imagem é interpretada como uma superfície topográfica, onde os níveis de cinza representam as altitudes dos vales e montanhas. É realizada a inundação desta superfície, as regiões são inundadas até que áreas com fluxos de água distintos fiquem prestes a se fundir, então é construída uma barragem sobre a superfície mais alta para prevenir a fusão dos fluxos. Finalmente, as únicas coisas visíveis da superfície serão as barragens. Estas barragens são chamadas de "*watershed lines*" e representam contornos de áreas distintas da imagem.

Neste trabalho, a metodologia de *watershed* será utilizada para a segmentação do volume encefálico global das outras estruturas presentes nas imagens de ressonância magnética. A ferramenta proposta seguirá a filosofia de distribuição livre, pois a maioria dos *softwares* para esse fim são proprietários e/ou necessitam de *hardware* específico. O objetivo primeiro da ferramenta é identificar automaticamente o volume encefálico global e assim auxiliar o processo de diagnóstico.

1.1 Motivação

Até a década de 1980, o maior emprego de imagens digitais era a pesquisa espacial (GONZALEZ; WOODS, 2008). Hoje é possível encontrar imagens digitais nas mais diversas aplicações devido ao barateamento da tecnologia. Tal difusão tem suporte no fato do ser humano utilizar a visão para grande parte das atividades que realiza. Tanto as atividades do cotidiano como as tarefas profissionais ou científicas dependem da percepção visual. Ler um livro ou revista, andar na rua, assistir a um filme, ou até visualização de dados científicos, de imagens médicas ou a edição de fotografias são todas atividades baseadas na aquisição de informação através de imagens.

Trabalhos recentes na área de segmentação e seleção semiautomática de objetos (SEIXAS et al., 2007; MORTENSEN; REESE; BARRET, 2000; MCINERNEY; TERZOPOULOS, 2000) demonstram o crescente interesse na semi-automatização dos processos de segmentação ou detecção de objetos. Mortensen e Barret (1998) destacam que a total automatização do processo de segmentação é um problema ainda sem solução. A semi-automatização destes processos abre um leque de possibilidades a diversos campos. Na medicina, há a possibilidade de utilização de técnicas semi-automatizadas para segmentação de imagens de ressonância magnética cerebral, visando a separação entre os elementos que merecem destaque à aplicação. O trabalho se encaixa no contexto do problema de detecção do encéfalo em imagens de ressonância magnética (HAHN; PEITGEN, 2000). Mesmo que a definição deste problema seja clara, não há uma solução definitiva publicada até o momento, como relatam Hahn e Peitgen (2000).

Neste contexto, o trabalho visa a obtenção de uma ferramenta para auxílio ao diagnóstico de neuropatologias utilizando as técnicas e algoritmos de segmentação e o paradigma de programação orientada a objetos. É interessante notar que a técnica geralmente aplicada para esta etapa é a seleção manual da região de interesse (pelo especialista). Além disso, o desenvolvimento da ferramenta é motivado também pela idéia de prover uma solução que aumente a praticidade e facilidade do diagnóstico, além de ser uma solução alternativa às ferramentas proprietárias disponíveis.

1.2 Objetivos

O objetivo primordial do trabalho é o desenvolvimento de uma ferramenta semiautomática para o processo de segmentação de imagens médicas. A ferramenta utiliza técnicas de processamento de imagens para detectar e marcar o volume encefálico global em imagens de ressonância magnética. A marcação

semiautomática de regiões tem por objetivo um possível auxílio no diagnóstico. Neste escopo, tem-se as seguintes funções para a ferramenta:

1. Ler imagens de ressonância magnética, tanto constituindo uma seqüência de cortes ou um volume e gerar uma representação volumétrica;
2. Localizar e demarcar de forma semiautomática o volume encefálico global.

Como atividades complementares e para garantir o cumprimento das funções supracitadas, a ferramenta deve:

- Ler os exames de ressonância magnética de encéfalo em formato DICOM (*Digital Imaging and Communications in Medicine*);
- Aplicar filtros de realce e detecção de bordas para melhorar o resultado da detecção;
- Aplicar a técnica de *watershed* sobre o volume tratado pelas etapas anteriores;
- Gerar uma imagem que represente o volume encefálico global localizado.

1.3 Organização do Trabalho

O trabalho está dividido em seis capítulos, na ordem que segue. O presente Capítulo 1 dá uma introdução ao tema e apresenta as motivações e objetivos do trabalho. Em seguida, são apresentados dois capítulos de embasamento teórico. O Capítulo 2 apresenta os conceitos de aquisição e visualização de imagens. Além disso, este capítulo apresenta a relação entre a área médica e a área de processamento de imagens, os diversos exames envolvidos e, em especial, descreve os princípios e características da ressonância magnética. O Capítulo 3 explana os conceitos de processamento de imagens envolvidos no trabalho. Os tópicos deste capítulo se dividem genericamente em: filtros de borrimento, filtros de detecção e realce de bordas e operações aritméticas e lógicas sobre imagens. Este capítulo também apresenta algumas técnicas de segmentação de imagens como a limiarização, a segmentação por similaridade e a segmentação por descontinuidade além de detalhar a técnica de *watershed*.

O Capítulo 4 apresenta a ferramenta desenvolvida, detalhando as bibliotecas utilizadas, os filtros e seu funcionamento, o conjunto de imagens utilizado e o *pipeline* desenvolvido para obter o resultado esperado. Este capítulo representa os materiais e métodos utilizados no desenvolvimento deste trabalho. O Capítulo 5 apresenta os resultados obtidos pela ferramenta e o Capítulo 6 apresenta as considerações finais a respeito do trabalho, bem como os trabalhos futuros envolvendo a ferramenta.

2 AQUISIÇÃO E VISUALIZAÇÃO DE IMAGENS

A aquisição e visualização de imagens é abordada neste capítulo. Primeiramente, é feita uma introdução, com a apresentação dos conceitos básicos, e em seguida são apresentados os métodos de aquisição e visualização científica para a medicina e os padrões definidos neste contexto. Prossegue-se com a apresentação dos métodos de aquisição e visualização de imagens anatômicas, a classe de imagens utilizada no trabalho, com destaque para Ressonância Magnética.

O capítulo está organizado da seguinte forma: a Seção 2.1 apresenta os conceitos básicos sobre a aquisição e visualização de imagens. Em seguida, a Seção 2.2 contextualiza a relação entre imagens e a área médica, apresentando os métodos de aquisição e visualização envolvidos e os padrões desenvolvidos para este fim, bem como caracteriza cada um dos métodos apresentados quanto a sua utilidade. A Seção 2.3 discorre sobre Ressonância Magnética e as imagens geradas por esta técnica. Finalmente, a Seção 2.4 resume o que foi apresentado.

2.1 Conceitos

Gonzalez e Woods (2008) apresentam o conceito de aquisição de imagens da seguinte forma:

A maioria das imagens em que estamos interessados são geradas através da combinação de uma fonte de 'iluminação' e a reflexão ou absorção da energia produzida por esta fonte nos elementos de uma 'cena' sendo adquirida. (GONZALEZ; WOODS, 2008, p. 46).

As palavras "iluminação" e "cena" foram utilizadas para representar um conceito mais amplo. A iluminação pode ser originária de uma fonte de energia eletromagnética, por exemplo, como no caso de radares, raios infravermelhos ou sistemas de raios-X e não apenas de uma fonte luminosa (GONZALEZ; WOODS, 2008). O passo seguinte é o registro da energia refletida. Este processo é realizado através de um sensor. O sensor depende do método utilizado e da

energia que se deseja registrar. Uma fotografia, por exemplo, é registrada através de um sensor que produz tensão proporcional à iluminação captada, enquanto que um raio-X é registrado através de um filme no qual incidem os raios-X que não foram absorvidos pelo objeto alvo. Uma imagem é dita digital quando a resposta do sensor for restringida a um conjunto finito e discreto de valores. Pode-se realizar a aquisição de imagens de diversas formas quanto à quantidade e disposição de sensores utilizados: utilizando apenas um sensor, sensores dispostos em linha (fila) ou até uma matriz de sensores.

2.1.1 Aquisição

Para obtenção de imagens bidimensionais através de um único sensor, é necessário que este seja movimentado sobre o alvo da aquisição. Por mais que a movimentação do sensor sobre o alvo possa ser precisa para garantir uma alta resolução (movimentos curtos), essa forma de aquisição é lenta. A obtenção de imagens através de sensores em fila é análoga, uma vez que se faz necessária a movimentação perpendicular à disposição dos sensores sobre o alvo para a aquisição de uma imagem bidimensional (2D). A aquisição com fila de sensores está ilustrada na Fig. 1. Segundo Gonzalez e Woods (2008) esta é a forma mais comum de aquisição utilizada por *scanners*.

Sensores dispostos em forma de anel é outra configuração possível para aquisição com fila de sensores. Neste caso é realizada a obtenção de uma representação tridimensional (3D) do objeto alvo através de múltiplas imagens bidimensionais. Para que isto seja possível, o posicionamento do objeto é alterado perpendicularmente ao sensor em anel, para aquisição de cortes do mesmo, conforme é ilustrado na Fig. 1. Em seguida estes cortes ou fatias do objetos são empilhadas para a obtenção de uma representação tridimensional. Gonzalez e Woods (2008) também destacam que os dados provenientes destes sensores devem ser processados por algoritmos de reconstrução, fazendo com que os dados se tornem uma representação válida de um corte do objeto. Este é o conceito básico da tomografia computadorizada. Outras modalidades que possuem essa abordagem são a tomografia por emissão de *positrons* (PET) e a Ressonância Magnética.

A abordagem de sensores em matriz é geralmente utilizada em câmeras digitais. Esta abordagem não requer a movimentação do sensor ou do objeto, portanto é mais vantajosa que os outros métodos. A matriz de sensores gera uma matriz de sinais analógicos que são posteriormente convertidos em sinais digitais.

A transformação de sinais analógicos em digitais envolve dois processos: amostragem e quantização. Uma imagem analógica é contínua tanto em




Figura 1: Aquisição de imagens utilizando fila de sensores.
 Adaptado de: (GONZALEZ; WOODS, 2008, p. 49)

amplitude de coordenadas quanto em seus valores de intensidade. Para realizar a conversão desta imagem para o domínio digital, é necessário discretizar ambos valores da imagem. A discretização da amplitude de coordenadas é chamada amostragem e a discretização dos valores de intensidade é chamada de quantização (GONZALEZ; WOODS, 2008). Estes conceitos podem ser visualizados na Fig. 2. É realizada a leitura de uma linha (Fig. 2(b)) da imagem analógica (Fig. 2(a)). Esta linha possui infinitos valores posicionais, ou seja, entre os pontos A e B na Fig. 2(b) há infinitos valores. Além disso, há infinitas intensidades na imagem analógica. Os processos de amostragem e quantização mapeiam determinadas faixas de valores analógicos em determinados valores discretos. O intervalo utilizado para estas faixas pode ser visto nas bordas superior e direita da Fig. 2(c). O resultado destes processos está ilustrado Fig. 2(d).

2.1.2 Visualização

As técnicas de visualização devem oferecer representações de dados compreensivas, enfatiza Oliveira (2002). Percebe-se assim que a aquisição de dados de nada serve se estes não puderem ser apresentados de forma a facilitar a usabilidade e compreensão. A representação mais comum para imagens são matrizes bidimensionais de *pixels*. No caso da medicina, há também a necessidade de uma visualização volumétrica do objeto em estudo. Essa representação tridimensional é gerada a partir das diversas fatias (imagens bidimensionais (x, y)) que representam os cortes do objeto. Estes cortes,

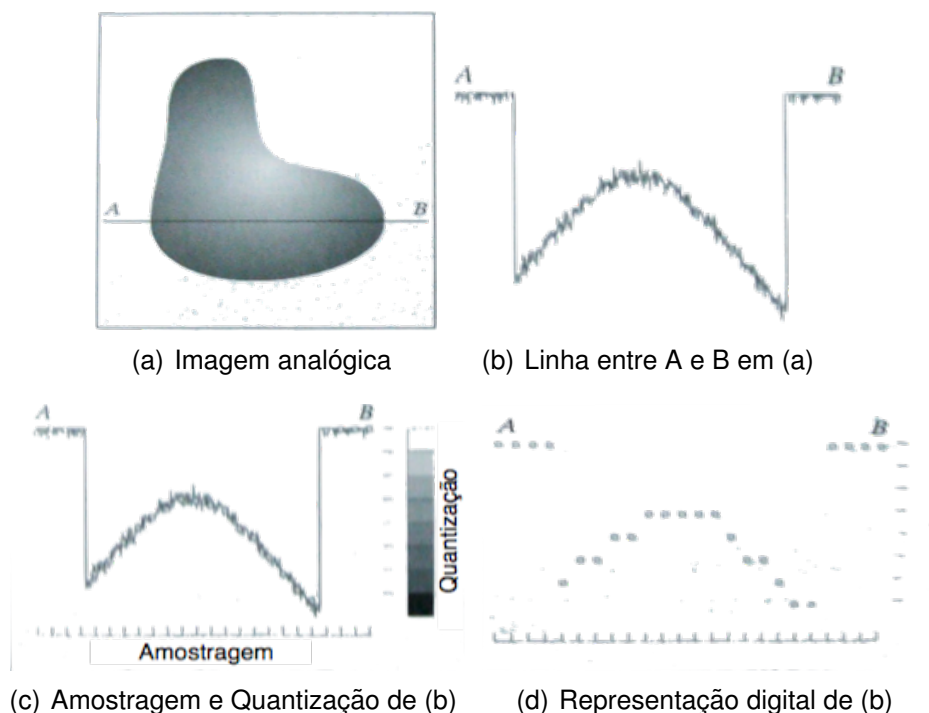


Figura 2: Amostragem e quantização.
Adaptado de: (GONZALEZ; WOODS, 2008, p. 53)

quando dispostos sobre o eixo z (empilhados), proporcionam uma representação volumétrica do objeto em estudo. Esta representação pode ser visualizada na Fig. 3.

Um conceito importante é o conceito de *voxel*. *Voxel* é a menor unidade finita de uma imagem tridimensional. O *voxel* pode ser visto como a extrapolação volumétrica de um *pixel*, isto é, a adição de informação do volume (dimensão z) a um *pixel* (que representa a informação espacial bidimensional). Este conceito também pode ser visualizado na Fig. 3, onde o espaço entre os cortes representa a informação volumétrica. Geralmente se dispõe de um grande número de



Figura 3: Representação volumétrica. Fonte: (RUSS, 2007, p. 692)

cortes, o que garante a precisão quanto ao volume do corte.

2.2 Imagens na Medicina

O advento das técnicas de processamento de imagens, no início dos anos 70, teve aplicação não somente na área espacial, mas também na geração de imagens para a medicina. Este é um campo de aplicação altamente relacionado com o processamento de imagens, que contribuiu e contribui fortemente para o desenvolvimento da área (GONZALEZ; WOODS, 2008). Essa colaboração entre as áreas produz benefício a ambas e, mais importante, beneficia a sociedade que faz uso das técnicas e ferramentas desenvolvidas quando realiza algum exame, por exemplo.

A seguir são apresentadas algumas modalidades de aquisição e visualização de imagens médicas desenvolvidas a partir da cooperação/interação entre as áreas.

2.2.1 Exames

O método de aquisição através de um sensor em anel é a base de modalidades de aquisição de imagens por tomografia como a ressonância magnética. Mas, além deste método, foram desenvolvidas outras formas de geração de imagens médicas. A saber, segundo Barros (2007):

Tomografia Computadorizada (TC) : *fótons* de raio-X são emitidos sobre o paciente e são detectados no lado oposto do aparelho, como visualizado na Fig. 1(b). Estes dados são lidos e quantificados para a geração de uma visualização tridimensional do paciente, após uma etapa de processamento que caracteriza a reconstrução através dos dados obtidos sobre os raios que atravessaram o paciente. O conjunto emissor/sensor de raios gira e se move perpendicularmente em torno do paciente para a obtenção de diferentes projeções.

Ressonância Magnética (RM) : são criados campos magnéticos de magnitude gigantesca capazes de alinhar os prótons de hidrogênio abundantes no corpo humano. Esta técnica baseia-se nas diferenças entre as propriedades de relaxamento magnético dos núcleos sob variação da intensidade do sinal de radiofrequência emitido e no registro da localização espacial da densidade de núcleos atômicos (DINIZ; SANTOS; JÚNIOR, 2007). Esta modalidade é utilizada para caracterização anatômica de tecidos moles do corpo humano.

Ultra-sonografia (US) : a aquisição é realizada através da emissão de ultra-

som (ondas sonoras com frequência acima de 1MHz). A diferença de tempo entre o momento da emissão de um pulso sonoro e o eco produzido quando este se choca com alguma superfície é utilizado para reconstrução da imagem. Esta técnica permite a visualização instantânea de órgãos e estruturas, como observa Barros (2007). Esta propriedade justifica sua utilização para visualização de fetos *in utero* ou a monitoração de problemas cardíacos através da visualização do fluxo sanguíneo (RUSS, 2007).

Medicina Nuclear (MN) : conjunto de métodos de aquisição que permeia um mesmo conceito: a geração de imagem é feita através da detecção de radiação que é emitida por alguma substância química introduzida no paciente e que se concentra no órgão alvo. Como exemplo podemos citar as imagens SPECT (*Single-Photon Emission Spectroscopy*) e *gated* SPECT, que são amplamente utilizadas em visualização cardíaca (BARROS, 2007; ZANCHET, 2007).

Yoo (2004 apud BARROS, 2007) divide as tarefas realizadas sobre imagens médicas em três grupos:

- filtragem, remoção de ruídos e realce;
- detecção de condições médicas ou eventos;
- análise quantitativa da lesão ou evento detectado.

É válido destacar que a detecção de lesões ou eventos significativos ao diagnóstico é, geralmente, uma interpretação do especialista. Esta subjetividade do diagnóstico dificulta a automatização do processo. Entretanto, atividades quantitativas, como mensurar o volume de um órgão, ou tumor, assim como calcular a extensão de uma lesão ou realçar imagens adquiridas, podem facilmente explorar as capacidades computacionais quanto à automatização pois não dependem de fatores subjetivos.

2.2.2 Padrão DICOM

O avanço da computação aplicada à medicina tornou necessária a criação de um método padrão para o armazenamento e transmissão de imagens médicas e seus atributos. Ainda na década de 70, o *American College of Radiology* (ACR, 2008) e a *National Electrical Manufacturers Association* (NEMA, 2008) formaram um comitê com o objetivo de definir este método. Em 1983 foi publicado a primeira versão do padrão, conhecido como *ACR-NEMA* e em 1985 publicado uma segunda versão. Antes destas definições os equipamentos

utilizavam formatos proprietários para o armazenamento e transmissão de imagens, dificultando a tarefa de comunicação entre equipamentos.

Apenas em 1993, com a publicação da terceira versão do padrão, sob o nome *DICOM (Digital Imaging and Communications in Medicine)* (DICOM, 2008a), foi possível estabelecer um padrão para o armazenamento e comunicação de imagens médicas e seus atributos. As informações do paciente, os relatórios, estudos e outras informações relevantes quanto a atividade foram padronizados (GOMES, 2007). Em adição, foi padronizada a forma de comunicação destas informações e das imagens em si. Esta versão trouxe avanços quanto a troca de imagens e informações entre equipamentos de diferentes fabricantes e quanto a facilidade no desenvolvimento e expansão dos sistemas de armazenamento e de comunicação, além da conexão com sistemas de informação médica (ZANCHET, 2007).

O padrão DICOM está na versão 3.0 e é mantido atualmente por uma divisão da NEMA, a *Medical Imaging Technology Alliance* (MITA, 2008). Esta versão expandiu as possibilidades quanto à comunicação em redes que eram providas pelas versões anteriores. Este padrão teve uma grande adoção, como observa Gomes (2007). A maioria das ferramentas desenvolvidas para processamento de imagens aplicada à medicina suporta o padrão DICOM. As informações a respeito da imagem é o que realmente torna o padrão DICOM poderoso. A integração entre as informações e as imagens em si facilita a sua adoção em diversas áreas, mesmo as que adotam métodos de aquisição e visualização diversificados. Podemos citar, entre as áreas distintas que fazem uso do padrão DICOM, áreas como a endoscopia, odontologia, oftalmologia e a dermatologia (DICOM, 2008b; CLUNIE, 2000).

Um arquivo definido no padrão DICOM é composto de duas partes. Uma parte compõe o cabeçalho: um conjunto de informações tanto sobre a imagem (como tamanho e quantidade de fatias, por exemplo), dados do paciente (se estes estiverem disponíveis) e informações sobre o exame em específico. A outra parte do arquivo é um conjunto de *bits* que representam os valores de intensidade de cada *pixel* de cada imagem do exame (uma representação do exame realizado). Como o formato suporta a representação de todas as imagens para a formação de um volume (dados volumétricos) são definidas duas formas para tal: a seqüência de *bits* pode representar todo o volume ou pode representar uma seqüência de imagens, cada qual um corte do exame (GOMES, 2007).




Figura 4: Ressonância magnética. Fonte: (JAN, 2006, p. 199)

2.3 Ressonância Magnética


As imagens na medicina podem ser classificadas em duas classes quanto ao que representam: imagens anatômicas que representam apenas a estrutura-formação, e imagens funcionais que ilustram o funcionamento de órgãos/tecidos. As imagens de Ressonância Magnética geram representações estruturais e portanto são classificadas como imagens anatômicas.

2.3.1 Princípio

O princípio da Ressonância Magnética baseia-se nas diferenças entre as propriedades de relaxamento magnético dos núcleos atômicos sob variação da intensidade do sinal de radiofrequência (RF) e no registro da localização espacial da densidade destes núcleos (DINIZ; SANTOS; JÚNIOR, 2007). A Fig. 4 ilustra simbolicamente este processo.

No exame de ressonância magnética, o objeto em estudo é colocado sob o efeito de um campo magnético homogêneo de alta intensidade (\mathbf{B}_0 na Fig. 4), fazendo com que momentos magnéticos das moléculas se alinhem (YUAN; GALLAGHER; CROZIER, 2005; FUJII, 2006). Em seguida, são emitidos pulsos de radiofrequência em direção ao campo a partir de determinado emissor de radiofrequência. Estes pulsos causam oscilações nos momentos magnéticos das moléculas que podem ser mensuradas. Dependendo de que emissor ou conjunto de emissores causou a oscilação no campo, pode-se identificar o ponto no espaço (x, y, z) que está sendo afetado. Esta seqüência de excitação-relaxamento do campo constitui a forma de aquisição da ressonância magnética.

Ademais, o tempo que os momentos magnéticos levam para se re-alinhar ao campo, após a emissão do pulso de radiofrequência, é utilizado para caracterizar a matéria constituinte do ponto sendo mensurado. Existe dois tipos de imagens



(a) Detalhamento quanto aos campos e radiofrequências (gradientes x e y) utilizadas (b) Campos perpendiculares (c) Arranjo completo da RM

Figura 5: Ressonância magnética detalhada. Fonte: (JAN, 2006, p. 200)

de ressonância magnética, diferenciadas basicamente pela forma de aquisição após o pulso de radiofrequência. Por definição, $T1$ é o tempo em que os *prótons* do tecido levam para recuperar aproximadamente 63% do alinhamento inicial e $T2$ é quando um pulso de radiofrequência faz com que os *prótons* entrem em fase e em seguida percam a coesão e fiquem fora de fase (DINIZ; SANTOS; JÚNIOR, 2007). As imagens do tipo $T1$ apresentam detalhamento anatômico preciso enquanto que as imagens $T2$ são utilizadas para reproduzir, com elevado nível de detalhe as condições patológicas, pois caracterizam os conteúdos hídricos do paciente. A precisão quanto à aquisição dos dados é garantida pelo método. A reconstrução das imagens a partir dos dados coletados é realizada através de complexos algoritmos (JAN, 2006).

A Fig. 5 mostra a estrutura da ressonância em detalhes. Pode-se ver pela figura como o campo magnético atua sobre o corpo do paciente, bem como o posicionamento dos emissores de radiofrequência. O posicionamento de tais elementos influencia diretamente na ação de excitação e relaxamento descrita, além de como é feita a leitura da ressonância.

2.3.2 Características

O exame por Ressonância Magnética é uma forma de aquisição de imagens a respeito de um paciente sem intervenção cirúrgica (não-invasiva) ou utilização de radiação ionizante. Ademais, seus agentes de contraste são muito mais seguros se comparados aos utilizados na tomografia computadorizada, como destaca Milani (2007). Junior (1999) também destaca o fato da ressonância magnética ser capaz de obter resultados bem melhores quanto à nitidez, principalmente no que diz respeito ao contraste da imagem gerada, e precisão no exame sem a necessidade de nenhum agente radioativo. Isso faz da ressonância magnética o método mais eficiente na detecção de lesões estruturais grosseiras em pacientes

com epilepsia do lobo temporal (OLIVEIRA, 2002 apud MILANI, 2007).

O impacto de certas doenças cerebrais pode ser avaliado e quantificado através da aquisição de dados volumétricos através de exames de ressonância magnética (SEIXAS et al., 2007). A análise de um exame de ressonância magnética geralmente demanda a análise visual de 60 a 120 cortes do objeto em estudo (HEYDEN et al., 1998). Além disso, Oliveira (2005) observa que a RM permite a obtenção das imagens nos planos Sagital, Coronal e Axial, como apresentado na Fig. 6.

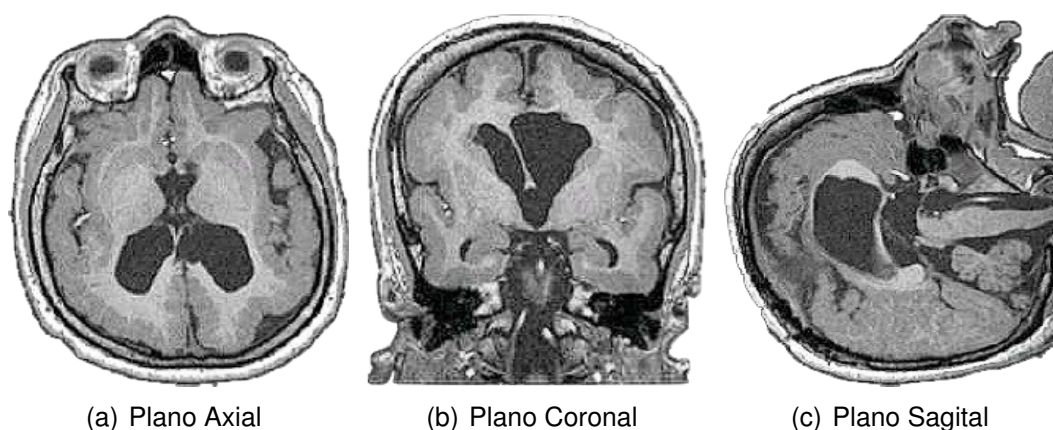


Figura 6: Imagens de RM nos 3 planos. Fonte: (FUJII, 2006, p. 22)

2.4 Síntese do Capítulo

Este capítulo apresenta os conceitos sobre aquisição e visualização de imagens. Os conceitos a respeito de sensores de aquisição, discretização de imagens (amostragem e quantização) são discutidos. O capítulo aborda também a representação dos dados adquiridos de forma bidimensional e tridimensional.

A seção discorre sobre a forte relação entre processamento de imagens e medicina, além de apresentar as diversas técnicas desenvolvidas para aquisição de imagens em exames médicos. É apresentado também o formato DICOM, um padrão para armazenamento e comunicação de imagens médicas digitais. Em seguida conceitua-se a técnica de Ressonância Magnética, apresentando seu princípio físico e caracterizando a aquisição de imagens através dessa técnica.

Evidencia-se, sobretudo, a importância das imagens para a área da medicina, bem como é possível ter uma visão clara das características e vantagens inerentes a cada método de aquisição, as formas de visualização utilizadas na área e os padrões utilizados para armazenamento e transmissão de imagens.

3 PROCESSAMENTO DE IMAGENS

Este capítulo trata da área de processamento de imagens, apresentando uma visão geral da área e elucidando conceitos relevantes ao trabalho. Entre os conceitos detalhados temos: as operações aritméticas e lógicas sobre imagens, realce de imagens através de filtros e segmentação de imagens.

A organização do capítulo é definida como segue. A Seção 3.1 introduz a área de processamento de imagens. Na Seção 3.2, são apresentados conceitos básicos de operações aritméticas e lógicas sobre imagens. A Seção 3.3 aborda as principais técnicas para o realce de imagens utilizando a aplicação de filtros e, em seguida, a Seção 3.4 apresenta as técnicas de segmentação de imagens. Dá-se destaque à técnica de *watershed* na Subseção 3.4.2. Finalmente, na Seção 3.5 é feita uma síntese do que é apresentado neste capítulo.

3.1 Visão Geral

O processamento digital de imagens diz respeito a qualquer atividade que, a partir de uma imagem digital de entrada, obtém por meio de um computador uma imagem ou conjunto de elementos úteis a uma determinada aplicação. Como exemplo temos os filtros de ruído, que eliminam tal propriedade em imagens digitais. Outro exemplo é a extração de características de uma imagem. Neste caso, a atividade se aproxima da área de análise de imagens pois produz atributos. Mas é possível considerá-la no contexto da área de processamento de imagens pois se trata de um evento que perpassa várias etapas, incluindo aí possivelmente filtragem, realce ou detecção de bordas sobre uma imagem digital, que são atividades da área de processamento de imagens.

A Fig. 7 dá idéia das diversas metodologias que podem ser aplicadas no processamento de imagens, com os mais diversos objetivos. Nota-se aqui que, dependendo do propósito da aplicação, as metodologias envolvem a produção de outras imagens digitais, como é o caso da aplicação de filtros, compressão ou restauração de imagens, ou atributos das mesmas, como no caso da média

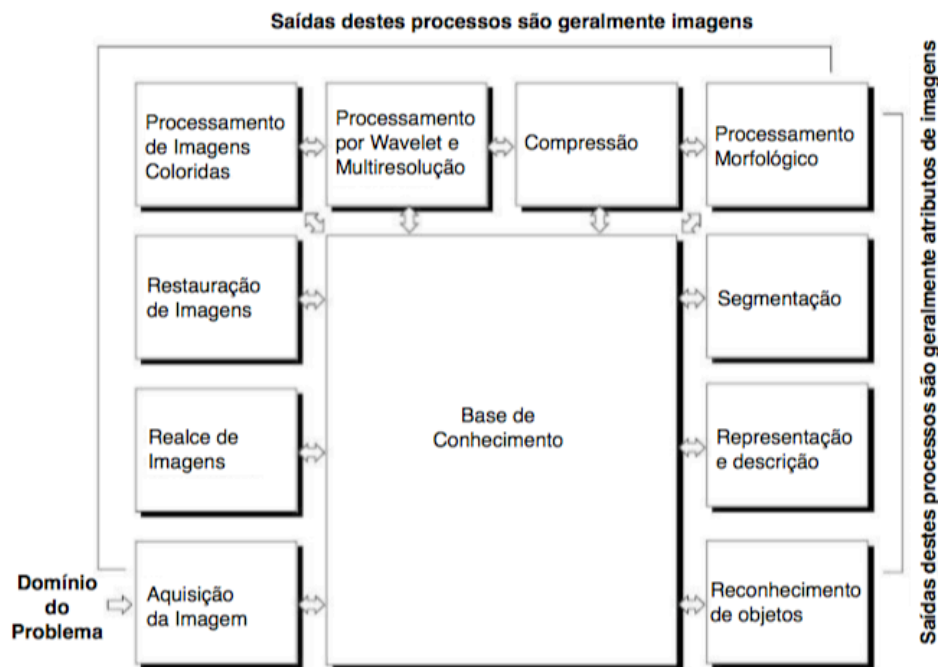


Figura 7: Metodologias utilizadas no processamento de imagens.
Adaptado de: (GONZALEZ; WOODS, 2008, p. 26)

de intensidade da imagem ou da extração de atributos previamente citada. O processo de segmentação pode gerar tanto uma imagem representando as regiões quanto atributos que as identifiquem.

Para a realização destes processos, parte-se de uma base de conhecimento gerada a partir de uma imagem digital. A aquisição desta imagem é realizada por um método específico, geralmente relacionado com o domínio da aplicação/problema. No caso de aplicações espaciais, por exemplo, pode usar-se um telescópio para a aquisição de imagens, enquanto que para uma aplicação médica, pode-se usar ressonância magnética, tomografia computadorizada, ou outros métodos. Percebe-se, assim, que o método de aquisição é fundamental para a geração de conhecimento a respeito do problema, pois está intimamente relacionada à forma de representação dos dados/imagens e, conseqüentemente, como eles/elas serão processadas.

Múltiplas tarefas podem ser combinadas para se alcançar o resultado esperado. Para imagens médicas, por exemplo, pode-se combinar várias etapas de processamento, entre as mais comuns estão a utilização de filtros para realce de estruturas como bordas ou pontos e a segmentação, como destacado por Yoo (2004 apud BARROS, 2007).

Uma imagem pode ser entendida como uma matriz de *pixels* (*picture elements*). Cada par (x, y) de coordenadas em um plano está relacionado a um valor de amplitude através de uma função f . A imagem da função $f(x, y)$

define os níveis de cinza ou a intensidade dos *pixels* da imagem. A imagem é dita digital quando o domínio e a imagem da função f são finitos e discretos, ou seja, quando o intervalo dos valores de x , de y e da função f são finitos e discretos (GONZALEZ; WOODS, 2008). A convenção utilizada por Gonzalez e Woods (2008) para representar imagem digital é apresentada na Fig. 8. O uso de filtros, como será visto posteriormente, tem como base esta representação para a aplicação de seus princípios matemáticos.

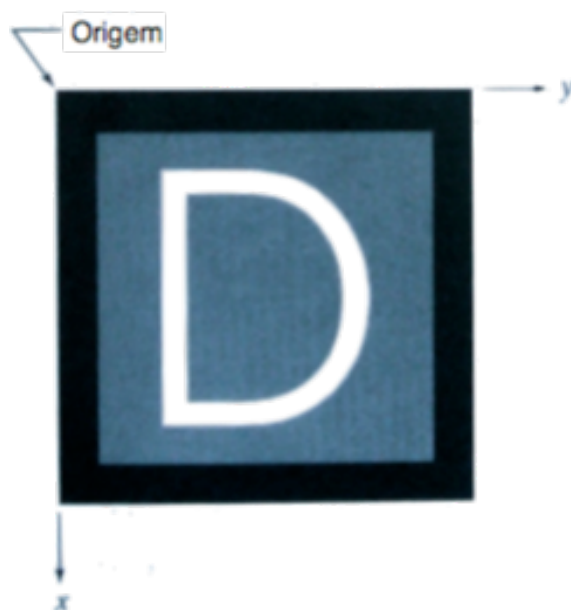


Figura 8: Uma imagem digital representada como um matriz de $M \times N$ pontos, onde cada ponto representa um *pixel*.

Adaptado de: (GONZALEZ; WOODS, 2008, p. 55)

3.2 Operações sobre Imagens

As operações aritméticas e lógicas sobre imagens podem ser aplicadas para os mais diversos fins. Pode-se realizar um mascaramento lógico através de uma operação lógica AND, por exemplo, ou aumentar o brilho de uma imagem através de uma adição entre imagens. Estas são operações sobre matrizes, sendo aplicadas portanto entre pares de *pixels* correspondentes entre as imagens.

As duas subseções seguintes detalham as operações aritméticas e operações lógicas sobre imagens (Subseção 3.2.1 e Subseção 3.2.2, respectivamente) bem como apresentam a aplicabilidade e exemplos de uso destas operações.

3.2.1 Operações Aritméticas

Definem-se as 4 operações básicas da aritmética para o uso sobre imagens: adição, subtração, multiplicação e divisão, como apresentado pelo conjunto de

equações em (1). Cada uma destas operações é utilizada com um fim específico.

$$\begin{aligned}
 adicao(x, y) &= f(x, y) + g(x, y) \\
 subtracao(x, y) &= f(x, y) - g(x, y) \\
 multiplicacao(x, y) &= f(x, y) \times g(x, y) \\
 divisao(x, y) &= f(x, y) \div g(x, y)
 \end{aligned}
 \tag{1}$$

Deve-se tomar cuidado especial ao se realizar operações aritméticas entre imagens. É de suma importância que o intervalo de valores não seja extrapolado, tanto na forma de *underflow* como de *overflow*. Soluções plausíveis para estes problemas incluem o truncamento ou a normalização dos valores, garantindo que o valor correspondente à intensidade do *pixel* se encontre dentro da faixa de valores utilizada. A adoção de um método específico está intimamente relacionado à natureza da aplicação segundo Centeno (2007).

3.2.1.1 Adição

A operação de adição entre duas imagens resulta em uma imagem onde a intensidade de um *pixel* é simplesmente a soma das intensidades dos *pixels* (de mesma coordenada) das duas imagens de entrada. A soma de duas imagens sobrepõe informações, o que é útil em composições onde há uma relação espacial complexa e, sobretudo, no momento de agregar o resultado de um filtro à imagem original (RUSS, 2007). Esta atividade é apresentada na Seção 3.3, sobre realce de imagens a partir de filtros.

3.2.1.2 Subtração

A subtração de imagens é amplamente utilizada. A subtração é primordialmente um meio para detectar diferenças entre imagens, como é possível visualizar através da Fig. 9. As partes da imagem que não sofreram alteração se anulam, resultando em um tom uniforme na imagem da diferença. No exemplo, a moeda que foi movida entre as duas aquisições Fig. 9(a) e Fig. 9(b) é destacada na Fig. 9(c). A região mais escura indica a posição original enquanto que a mais clara indica a posição de final. Além disso, um uso comum para a operação de subtração é a eliminação do fundo de uma imagem.

A subtração entre imagens tem utilidade nas mais diversas áreas. Podemos citar, dentre várias, o controle de qualidade, a detecção de movimento e a extração de regiões. Para o controle de qualidade, é possível detectar a falta de algum componente através da subtração entre a imagem do produto adquirida durante a fabricação e um molde que simule o posicionamento dos componentes.




Figura 9: Diferença entre imagens. Fonte: (RUSS, 2007, p. 319)

A detecção de movimento explora a subtração para mensurar o deslocamento de um objeto que seja grande o suficiente. A extração de regiões basicamente utiliza a subtração para eliminar regiões que não sejam de interesse no contexto de uma aplicação.

3.2.1.3 Multiplicação

A multiplicação é talvez a operação aritmética menos utilizada, segundo Russ (2007). A operação pode ser utilizada para sobrepor ou mesclar duas imagens, como no caso da adição de uma textura à uma superfície. De forma similar, pode-se adicionar fluorescência ou outro tipo de emissão à uma imagem. A extrapolação da magnitude dos valores obtidos é um problema inerente a esta operação e deve ser tratado.

Esta operação pode também ser utilizada para mascaramento lógico. As regiões de interesse são demarcadas com valores 1, e o restante é definido com valor 0. Geralmente se define regiões de interesse através de retângulos, por facilidade de implementação, mas não é regra (GONZALEZ; WOODS, 2008). A Fig. 10 demonstra tal aplicação, onde a Fig. 10(b) é utilizada como máscara (deixará passar apenas os valores demarcados com determinado valor) sobre a Fig. 10(a). O resultado desta operação sobre as imagens Figs. 10(a) e 10(b) é ilustrado na Fig. 10(c).

3.2.1.4 Divisão

A divisão enfrenta o problema da extrapolação da faixa da mesma forma que a multiplicação, mas além disso tem de evitar a divisão por 0. O problema da divisão é resolvido essencialmente adicionando 1 a todos os valores de intensidade.

Um dos usos da divisão diz respeito à separação da imagem por faixas de intensidades ou comprimento de onda. Utilizando como base a faixa de absorção




Figura 10: Mascaramento. Fonte: (GONZALEZ; WOODS, 2008, p. 79)

de raios infra-vermelhos de cada material, pode-se identificar corretamente cada um, por exemplo. Esse exemplo mostra aplicabilidade na detecção de diferentes materiais em minas ou até aplicações espaciais que visam identificar a formação de um corpo celeste. Variações desse método são utilizadas para detectar diversos elementos através de imagens terrestres de satélite, por exemplo: detectar vegetação, areia/desertos, rochas, concentração de clorofila nos oceanos, entre outros (SABINS, 1987 apud RUSS, 2007).

3.2.2 Operações Lógicas

As operações lógicas podem ser utilizadas no intuito de combinar informações de várias imagens ou canais. São definidas três operações lógicas básicas aplicadas a imagens binárias: *AND*, *OR*, e *NOT*. As operações *AND* e *OR* são aplicadas entre duas imagens, entre pares de *pixels* de mesma posição, enquanto a operação *NOT* é aplicada a apenas uma imagem. Um conceito inerente à imagens binárias é a definição de *pixel* ligado ou desligado. Um *pixel* é dito ligado quando representa um valor *verdadeiro* e desligado quando representa um valor lógico *falso*. Geralmente o nível 1 (branco) é utilizado para representar o valor lógico *verdadeiro* e o nível 0 (preto) é utilizado para representa o valor lógico *falso*, mas não há consenso para essa terminologia na literatura (RUSS, 2007). A Fig. 11 ilustra as três operações lógicas definidas além da operação *XOR* (*OR*-exclusivo) que pode ser obtida através das três operações lógicas básicas.

A operação *AND* necessita que o par de *pixels* tenha valores ligados para que o *pixel* resultante seja ligado. Qualquer *pixel* desligado em uma das imagens resulta em um *pixel* desligado na imagem resultante. Assim, a operação *AND* representa o conjunto de valores que são comuns a ambas imagens.

A operação *OR* liga um *pixel* na imagem resultante se qualquer um dos *pixels* de mesma posição em qualquer uma das duas imagens de entrada esteja ligado.

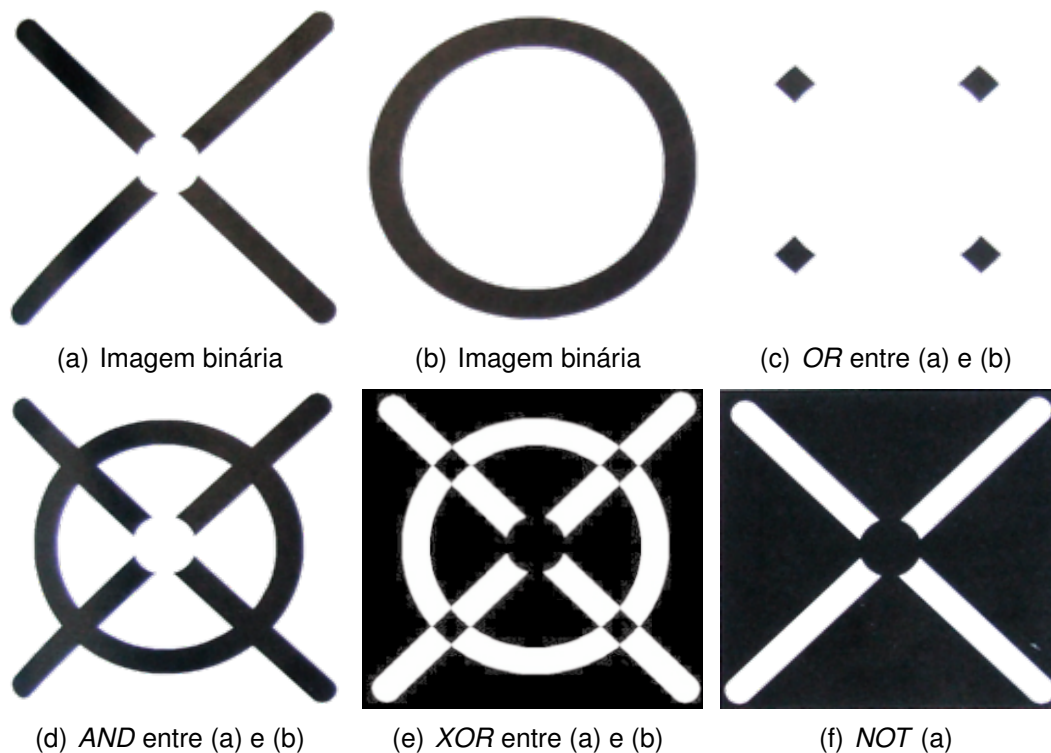


Figura 11: Operações lógicas. Fonte: (RUSS, 2007, p. 445)

De forma semelhante funciona a operação *XOR*: ela liga os *pixels* cujos valores estejam ligados em alguma das imagens, mas diferentemente da operação *OR*, ela não liga os *pixels* que estejam ligados em ambas as imagens.

A negação, operação *NOT*, gera o complemento dos *pixels* da imagem, ou seja, faz com que os valores que estiverem ligados na imagem de origem sejam desligados e vice-versa.

As definições acima tomam como base duas imagens binárias. É possível também utilizar uma imagem binária como máscara para alterar uma imagem em tons-de-cinza. Isso é útil geralmente quando se deseja remover o fundo de uma imagem ou destacar regiões de interesse. Utiliza-se, para este fim, as operações lógicas *AND* e *OR*. Neste caso específico, as operações funcionam como produto e soma lógicos, respectivamente.

Segundo Centeno (2007), as operações lógicas são ferramentas básicas para o processamento de imagens binárias utilizadas para a extração de características e análise de formas.

3.3 Realce de Imagens

A etapa de realce de imagens vai além de simplesmente corrigir defeitos da etapa de aquisição. Os métodos de realce tem por objetivo melhorar a visibilidade de uma área da imagem, seu aspecto, ou determinado componente

da imagem, diminuindo conseqüentemente o destaque aos demais elementos/componentes (RUSS, 2007). É bom destacar que as áreas da imagem, mesmo sendo realçadas, não são removidas.

Há diversos fins para se realizar o realce de imagens. Para Gonzalez e Woods (2008), o realce de imagens visa primordialmente tornar a imagem mais adequada ao contexto de uma aplicação. Podemos incluir as definições de Facon (2005) para os principais objetivos do realce de imagens:

- obter uma imagem com um contraste adequado;
- tornar os contornos nítidos;
- enriquecer detalhes importantes;
- diminuir o ruído o máximo possível.

A avaliação da qualidade do processo de realce é realizada de forma subjetiva, como destacado por Gonzalez e Woods (2008). Esse ponto torna a automatização dessa etapa uma tarefa complexa. Além disso, é necessário que se defina critérios para a avaliação de tal etapa.

O processamento de imagens com intuito de realce pode ser realizado tanto no domínio espacial, isto é, no conjunto de *pixels* que compõe a imagem, como no domínio da frequência. No trabalho é dado enfoque ao realce explorando o domínio espacial. Nesse tipo de processamento o valor do *pixel* é alterado de acordo com regras que dependem do valor atual do *pixel*. Além disso, pode-se realizar um processamento que considera o valor da vizinhança (*pixels* vizinhos) das mais variadas formas, como a média ou a mediana dos valores de vizinhança (RUSS, 2007). A Eq. (2) expressa as transformações no domínio espacial

$$g(x, y) = T[f(x, y)] \quad (2)$$

onde $f(x, y)$ representa a imagem de entrada, $g(x, y)$ representa a imagem de saída, e T é a transformação aplicada sobre a imagem f tendo como referência o ponto (x, y) .

A Fig. 12 apresenta a aplicação da Eq. (2) sobre uma imagem. O ponto (x, y) é um ponto arbitrário, e a pequena região destacada é a vizinhança de (x, y) . A vizinhança geralmente é retangular, centralizada em (x, y) , e bem menor que a imagem. O processamento da imagem da Fig. 12 é realizado *pixel a pixel*, isto é, o ponto de referência (x, y) é alternado entre todos os *pixels* da imagem e, para cada um, a transformação T é aplicada para obtenção do valor de saída para a mesma posição, $g(x, y)$. Este processo é realizado a partir da origem e procede linha a linha. Quando o *pixel* se encontra na borda da imagem, a vizinhança

que está fora dos limites da imagem é desconsiderada (GONZALEZ; WOODS, 2008).

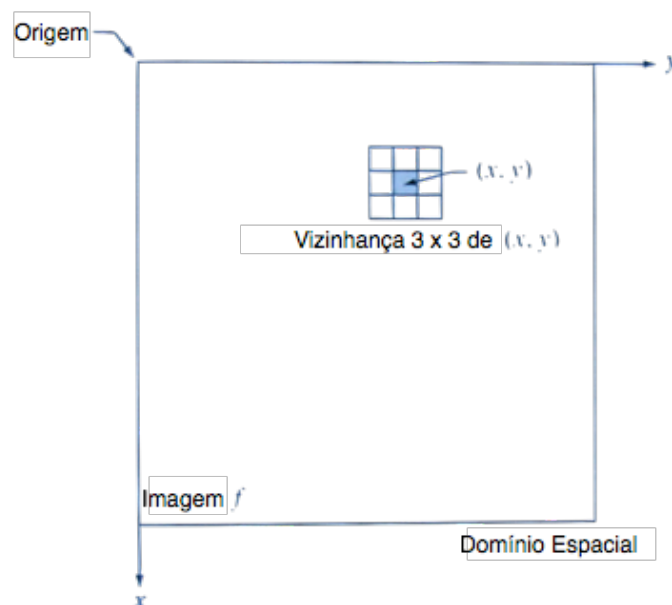


Figura 12: Transformação espacial. Vizinhança de tamanho 3×3 para aplicação de uma transformada T em um ponto (x, y) de uma imagem. Adaptado de: (GONZALEZ; WOODS, 2008, p. 105)

Partindo destes conceitos básicos, as seções seguintes visam apresentar os tipos de filtros utilizados durante o trabalho. A Seção 3.3.1 apresenta os filtros de suavização ou borrimento, uma etapa de pré-processamento. Em seguida, a Seção 3.3.2 apresenta os filtros de alta frequência ou gradiente, para detecção simples de bordas que é umas das etapas de pré-processamento.

3.3.1 Filtros de Suavização

Os filtros de suavização são utilizados com o objetivo de redução do ruído ou borrimento da imagem. Um filtro de suavização é utilizado para borrimento da imagem, como um etapa de pré-processamento, diminuindo pequenos detalhes irrelevantes para a etapa seguinte. O filtro de borrimento, neste caso, elimina pequenas estruturas, como espaços, linhas e pontos que não são importantes no momento da segmentação de estruturas maiores.

A saída de um filtro de suavização é a média do valor dos *pixels* da vizinhança (GONZALEZ; WOODS, 2008). Esse funcionamento justifica a denominação de tais filtros como *filtros de média*. Além disso estes filtros são conhecidos também como *filtros passa-baixa*, pois eliminam as altas frequências (ruídos e transições bruscas) nas imagens.

O filtro de suavização gera a média das intensidades dos *pixels* da vizinhança definida pela máscara, possibilitando uma interação maior entre os *pixels*, e

assim reduzindo as transições bruscas de intensidade. Seguindo essa linha de raciocínio, nota-se a utilidade desse filtro para redução de ruído, que são transições bruscas de intensidade. Porém, a aplicação do filtro de suavização causa o borramento da imagem como um todo, inclusive das bordas de estruturas, propriedades relevantes para grande parte das aplicações. É possível aplicar um filtro de borramento sem afetar a estrutura da imagem (as bordas) com uma heurística e custo extra.

As máscaras utilizadas no filtro podem variar seus pesos, isto é, cada *pixel* é multiplicado por um valor diferente, dando assim mais importância a determinados *pixels*. Esse tipo de filtro é chamado *filtro de média ponderada*. Geralmente, usa-se o *pixel* central como ponto de referência de importância e a medida que nos distanciamos deste, reduz-se a importância do *pixel*. Conseqüentemente, o borramento neste caso é reduzido a medida que nos distanciamos do centro da máscara.

O tamanho do filtro afeta o grau de borramento, como é ilustrado na Fig. 13. Esta figura representa o funcionamento do filtro de suavização utilizando, respectivamente, máscaras quadradas de 3, 5, 9, 15 e 35 *pixels* de lado. Do resultado faz-se a seguinte consideração: o tamanho da máscara afeta de forma proporcional o borramento de estruturas de mesmo tamanho da mesma, isto é, uma máscara de 3×3 *pixels* afeta uma estrutura com dimensão aproximada de 3×3 de forma mais efetiva do que uma estrutura maior do que a máscara. É possível observar esse comportamento na Fig. 13, notando claramente que o borramento é intensificado pelo aumento da máscara (afetando as estruturas maiores de forma mais significativa) e que o tamanho da máscara afeta de forma direta o tamanho das estruturas que serão *mescladas* com o fundo. Máscaras maiores são utilizadas para eliminar elementos pequenos em imagens, por apresentarem um borramento mais pronunciado (GONZALEZ; WOODS, 2008).

A Fig. 14 exemplifica o uso de um filtro de suavização estatístico, o filtro de mediana, e compara o resultado deste filtro com o filtro de média. Neste caso, usa-se a mediana dos valores da vizinhança para determinar o valor resultante do *pixel*. Obtém-se, assim, um valor de *pixel* que é mais semelhante à vizinhança. Este tipo de filtro é popular para a redução de ruído do tipo sal-e-pimenta (*salt-and-pepper*), pois é capaz eliminar pequenos pontos com intensidades muito discrepantes (tanto escuros como claros) em relação a seus vizinhos, característicos desse tipo de ruído. Existem vários filtros estatísticos, sendo mais comumente utilizado o filtro de mediana.

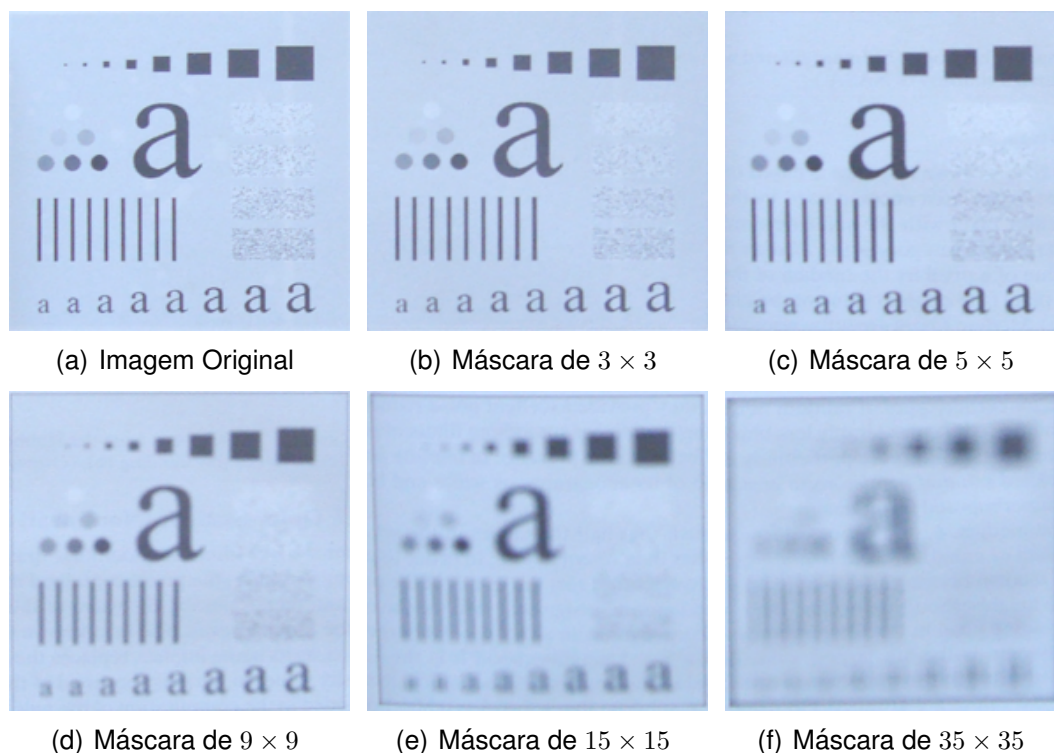



Figura 13: Filtro de suavização. Influência do tamanho da máscara no borramento.

Fonte: (GONZALEZ; WOODS, 2008, p. 155)



(a) Imagem de Raio-X de um (b) Imagem resultante da (c) Imagem resultante da
circuito corrompido por ruído aplicação do filtro de média aplicação do filtro de mediana
“sal e pimenta” 3×3 sobre (a) 3×3 sobre (a)

Figura 14: Filtro de média e de mediana.

Fonte: (GONZALEZ; WOODS, 2008, p. 157)

3.3.2 Filtros de Alta Frequência

Os filtros de alta frequência ou gradiente objetivam realçar transições de intensidade na imagem (GONZALEZ; WOODS, 2008). A intensidade de resposta do filtro é proporcional à intensidade da transição no ponto onde o filtro é aplicado. O funcionamento deste tipo de filtro é baseado em derivadas ou aproximações digitais de derivadas. A aplicação desse filtro dá realce às bordas e outras transições através da diferenciação espacial e releva áreas contínuas.

São utilizadas, geralmente, aproximações de derivadas de primeira e segunda ordem. Cada uma destas aproximações deve modelar as transições, bruscas ou não, de forma a exaltá-las. As aproximações para a derivada de primeira ordem devem possuir as seguintes propriedades:

1. ser zero em áreas de intensidade constante;
2. ser não-zero em transições bruscas ou suaves;
3. ser não-zero em rampas de intensidade (variação constante).

Pode-se visualizar a modelagem destas propriedades através da Eq. (3). É utilizada a notação de derivada parcial (∂) pois se trata de uma aproximação digital, restrita às propriedades apresentadas. A equação, exemplificada com apenas uma variável (x) por simplicidade, descreve a interação entre o *pixel* atual e seu vizinho posterior, caracterizando uma transição.

$$\frac{\partial f}{\partial x} = f(x + 1) - f(x) \quad (3)$$

A aproximação da derivada de segunda ordem pode ser modelada através da Eq. (4). Nota-se que a interação ocorre não apenas entre o *pixel* de referência e o próximo, mas também com o *pixel* anterior. Essa equação demonstra as propriedades que a aproximação da segunda derivada deve possuir. A saber:

1. ser zero em áreas de intensidade constante;
2. ser não-zero em transições bruscas ou suaves;
3. ser zero em rampas de intensidade (variação constante).

$$\frac{\partial^2 f}{\partial x^2} = f(x + 1) + f(x - 1) + 2f(x) \quad (4)$$

A terceira propriedade, que difere as derivadas de segunda ordem das de primeira, é assegurada através da relação entre *pixel* anterior, *pixel* posterior e o de referência. A equação apresenta a forma utilizada para detecção de variações constantes.

Fica claro que as derivadas de primeira e segunda ordem têm aplicação distinta. Enquanto as primeiras são capazes de detectar pequenas variações de detalhes, realçando-os de forma mais crua, as segundas são capazes de realçar detalhes mais finos da imagem. Esta é uma propriedade importante para o aguçamento de imagens (realce de bordas, variações) (GONZALEZ; WOODS, 2008).

Tomando como base as definições estabelecidas, é necessário a obtenção das aproximações para uma imagem, portanto funções de duas variáveis (x e y). Finalmente é construído uma máscara baseada em tais formulações. O filtro obtido através da aproximação da derivada de primeira ordem é chamado filtro de gradiente. É comum chamar as imagens resultantes do processo de realce por um filtro de primeira derivada de imagem de gradiente ou apenas gradiente. Neste caso, são computadas as derivadas parciais através de duas máscaras (uma para o eixo x e outra para o eixo y). Da aplicação destas máscaras é obtido a magnitude $M(x, y)$ do vetor de gradiente:

$$M(x, y) = \text{mag}(\nabla f) = \sqrt{g_x^2 + g_y^2} \quad (5)$$

Note que $M(x, y)$ é a imagem de gradiente. A Fig. 15 apresenta duas máscaras para o filtro de gradiente, conhecidas como operadores de *Sobel*, ou simplesmente filtro de *Sobel*. A idéia dessa máscara é dar maior importância ao *pixel* central através da atribuição de um valor maior que o restante da máscara. O resultado da aplicação de tais máscaras é ilustrado na Fig. 16. O resultado mostra a aplicação do filtro para realce de detalhes, como as imperfeições da lente de contato no exemplo ilustrado.

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


(a) Aproximação da derivada parcial para o eixo x (b) Aproximação da derivada parcial para o eixo y

Figura 15: Operadores de Sobel. Fonte: (GONZALEZ; WOODS, 2008, p. 166)

O filtro é construído a partir da aproximação digital da derivada de segunda ordem. Este filtro é conhecido como filtro *Laplaciano* e é ilustrado pelas máscaras da Fig. 17. A aplicação desse filtro tende a produzir imagens com linhas e outras discontinuidades em tons de cinza sobre um fundo escuro. A Fig. 18 apresenta o resultado da aplicação do filtro, que pode ser somado à imagem original se o desejo é realçar as linhas originais e não apenas identificá-las.

3.4 Segmentação de Imagens

O ser humano efetua agrupamentos do que percebe pela visão, baseando-se na proximidade, similaridade e continuidade ou discontinuidade dos objetos




(a) Imagem Original de uma lente de contato (b) Aplicação do Filtro de *Sobel* para obtenção do gradiente

Figura 16: Filtro de gradiente. Fonte: (GONZALEZ; WOODS, 2008, p. 168)

0	1	0	1	1	1	0	-1	0	-1	-1	-1
1	-4	1	1	-8	1	-1	4	-1	-1	8	-1
0	1	0	1	1	1	0	-1	0	-1	-1	-1
	(a)			(b)			(c)			(d)	

Figura 17: Máscaras de *Laplace*. (a)–(d) exemplos de máscaras do filtro *Laplaciano*.

Fonte: (GONZALEZ; WOODS, 2008, p. 161)



(a) Imagem Original (b) Resultado da aplicação do Filtro *Laplaciano*

Figura 18: Filtro *Laplaciano*. Fonte: (GONZALEZ; WOODS, 2008, p. 163)

que vê. A visão computacional procura, de forma análoga, basear-se na segmentação como princípio para identificação de objetos.

O processo de segmentação divide uma imagem em suas regiões ou objetos constituintes (GONZALEZ; WOODS, 2008). Escolher as características ou elementos de uma imagem é um requisito importante para a maioria das análises

ou quantificações sobre imagens (RUSS, 2007).

Facon (2005) enfatiza:

O alvo da segmentação é obter, a partir de uma imagem digitalizada pré-processada, um conjunto de “primitivas ou segmentos significativos” que contém informação semântica relativa à imagem de origem (FACON, 2005, p. 51).

É válido destacar, segundo Gonzalez e Woods (2008), que a segmentação de imagens é a atividade de maior complexidade dentro da área de processamento de imagens. A precisão do processo de segmentação influencia diretamente no sucesso ou o fracasso das etapas posteriores e, naturalmente, no resultado da aplicação como um todo.

Yoo (2004 apud BARROS, 2007) define a segmentação no contexto do processamento de imagens médicas como o conjunto de ferramentas e técnicas que visam identificar regiões contíguas na imagem que representam determinado tecido ou órgão.

Os métodos de segmentação de imagens geralmente são classificados em três grupos, de acordo com Gonzalez e Woods (2008):

- Limiarização ou *Thresholding*
- Segmentação por descontinuidade ou detecção de bordas
- Segmentação por similaridade ou baseada em crescimento ou divisão e fusão de regiões

Na Subseção 3.4.1 é feita uma apresentação de algumas técnicas de segmentação de imagens, apontando suas vantagens, desvantagens e aplicações. A técnica de *watershed* é discutida na Subseção 3.4.2.

3.4.1 Técnicas de Segmentação

Geralmente, a forma mais simples de selecionar elementos de uma imagem é definir um intervalo de intensidades sobre a imagem original e desse intervalo selecionar os *pixels* como pertencentes ao fundo (fora do intervalo) ou ao objeto de interesse (pertencentes ao intervalo). Essa representação é comumente feita através de uma imagem binária, ou preto-e-branco, para distinção das regiões. Essa técnica é conhecida como limiarização ou *thresholding*.

Além disso, pode-se dividir o processo de segmentação de imagens em mais duas classificações segundo propriedades dos valores de intensidade de *pixel*: *descontinuidade* e *similaridade*. Para o primeiro caso, as mudanças abruptas dos valores de intensidade delimitam as regiões. Já para o segundo caso, a

propriedade utilizada é a similaridade entre os elementos, seguindo um critério pré-definido.

As seções abaixo discutem os métodos citados. A Subseção 3.4.1.1 trata do método de limiarização ou *thresholding*. Em seguida, a Subseção 3.4.1.2 apresenta as técnicas baseadas em segmentação por descontinuidade ou detecção de bordas. Finalmente, o tema é concluído na Subseção 3.4.1.3 que apresenta as técnicas de segmentação baseadas em similaridade.

3.4.1.1 Limiarização

A limiarização é o método mais simples e intuitivo de segmentação de imagens (GOMES, 2007). A classificação dos *pixels* é feita através da definição de um intervalo de intensidades. Os *pixels* que se encontram dentro da faixa são classificados como pertencentes à região enquanto os *pixels* que estão fora da faixa são classificados como não pertencentes à região. A representação do resultado desse tipo de segmentação geralmente é uma imagem binária: os *pixels* que são classificados como não pertencentes à região (possuem intensidade maior que um valor de limiar T) recebem o valor máximo de intensidade enquanto os *pixels* restantes recebem o valor mínimo. A Eq. 6 descreve esse funcionamento, onde $g(x, y)$ representa a imagem binária:

$$g(x, y) = \begin{cases} 1 & f(x, y) \geq T \\ 0 & f(x, y) < T \end{cases} \quad (6)$$

O histograma da imagem resultante apresenta uma distribuição apenas entre dois valores: a quantidade de *pixels* com valor máximo concentrada à direita e a quantidade de *pixels* com valor mínimo concentrada à esquerda. Todas as intensidades à esquerda do valor de limiar T no histograma da imagem original foram concentradas no valor mínimo e as frequências maiores ou iguais ao limiar passaram a se concentrar no valor máximo.

Além disso, o histograma (distribuição dos valores de intensidade quanto a sua quantidade) da imagem pode servir de base para segmentação usando mais de um valor de limiar. Pode-se identificar regiões de intensidade constante através picos no histograma e, na seqüência, usar essa informação para caracterização de uma região. Segundo Russ (2007), esse método é raramente aplicado para imagens reais. Um dos motivos da baixa utilização do método para aplicações reais deve-se à pouca precisão inerente ao método de seleção do limiar no histograma. Mas sobretudo, o que leva a pouca utilização do método é a desconsideração da informação espacial/estrutural, pois o histograma não apresenta informações sobre o posicionamento dos *pixels*. Logo, a aplicação da delimitação através de histograma não apresenta resultados

interessantes quando se deseja a identificação de detalhes estruturais com precisão. A delimitação usando histograma é geralmente utilizada quando é possível controlar as condições da imagem, como iluminação adequada.

A limiarização pode ser utilizada em uma etapa de pré-processamento de uma aplicação. Porém, quando o objetivo é obter uma separação entre fundo e um objeto de forma simples e rápida, a limiarização é a solução mais indicada (FACON, 2005). A Fig. 19 ilustra um exemplo de limiarização, onde o histograma obtido da imagem de entrada é utilizado para definir o valor de limiar (neste caso a intensidade 127), fazendo com que os valores de intensidade maiores que este limiar sejam definidos como 1 (branco) e os valores menores que este limiar sejam definidos como 0 (preto). A Fig. 19(a) representa a imagem de entrada no exemplo, a Fig. 19(b) representa o histograma desta, e a Fig. 19(c) representa o resultado da operação.

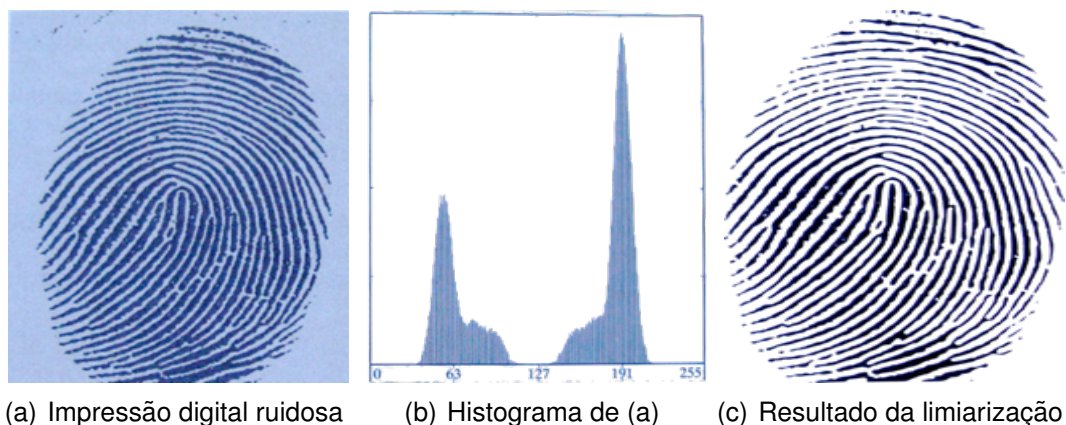


Figura 19: Segmentação por limiarização.

Fonte: (GONZALEZ; WOODS, 2008, p. 743)

3.4.1.2 Segmentação por Descontinuidade

Na segmentação por descontinuidade, segundo Milsztajn (2003), assume-se que a borda de uma região é suficientemente diferente em intensidade da borda da região adjacente e do fundo (mudança abrupta de intensidade). Estas propriedades podem ser visualizadas na Fig. 20, onde é apresentado a máscara e a imagem de entrada (Figs. 20(a) e 20(b), respectivamente) e o resultado da aplicação do filtro destacando uma transição brusca representada pelo pequeno ponto demarcado por um círculo. Nessa categoria estão os métodos baseados em filtros de detecção de bordas como filtro *Laplaciano* e de gradiente (Seção 3.3.2). Comumente a transição que representa uma borda é gradual, devido ao efeito gerado pela amostragem (GONZALEZ; WOODS, 2008).

Após a primeira etapa de detecção de bordas através dos filtros descritos, é necessário que as regiões sejam delimitadas. Os algoritmos de segmentação

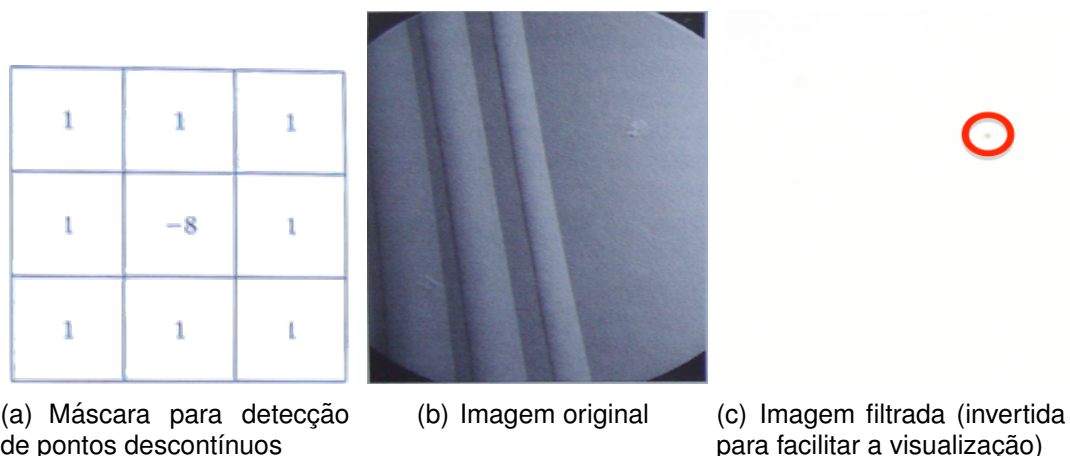


Figura 20: Segmentação por descontinuidade.

Fonte: (GONZALEZ; WOODS, 2008, p. 697)

baseados em descontinuidade geralmente são capazes de interligar os pontos de segmentos obtidos na etapa inicial, visando assim a obtenção de formas geométricas que delimitem as regiões de interesse de forma que estas possam ser estudadas. Deve-se tomar especial cuidado, segundo Milsztajn (2003), com o efeito de ruídos sobre o processamento do algoritmo. Os ruídos podem fazer com que o algoritmo produza formas desconexas e irrelevantes ao estudo.

Na Fig. 21, é apresentado um exemplo do resultado da segmentação por detecção de bordas em uma imagem de tomografia computadorizada. A Fig. 21(a) ilustra a imagem de TC e a Fig. 21(b) ilustra a imagem resultante da segmentação. A imagem resultante apresenta apenas as bordas destacadas, portanto há a necessidade de uma etapa extra: a união dos pontos identificados como bordas para realmente formar uma região. Esta necessidade é a principal desvantagem na utilização de métodos baseados em detecção de borda.

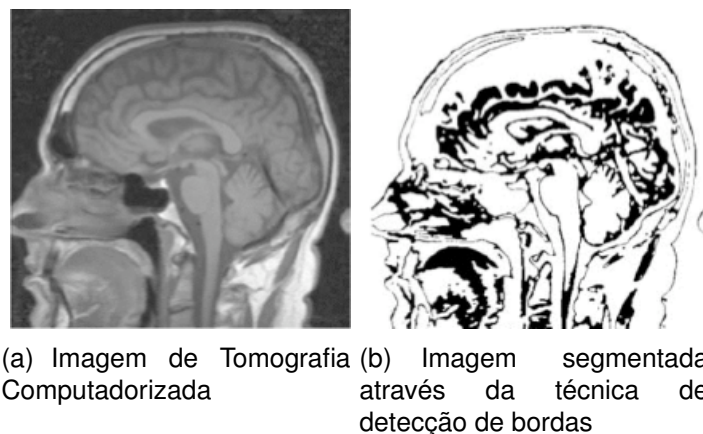


Figura 21: Segmentação por detecção de bordas. Fonte: (JAN, 2006, p. 619)

3.4.1.3 Segmentação por Similaridade

Nos métodos baseados em segmentação por similaridade, a região é definida como conjunto de *pixels* que possuem características comuns. As duas técnicas mais conhecidas nesta classificação são: o crescimento de regiões (*Region Growing*) e o método da divisão e fusão (*Split and Merge*). As duas técnicas citadas são apresentadas abaixo.

O método de crescimento de regiões visa expandir pequenos grupos de *pixels* com determinado nível de similaridade em grupos maiores. A partir de uma semente, como são chamados os pontos iniciais de referência, a região cresce à medida que se detecta semelhanças entre os *pixels* da vizinhança. As semelhanças, ou propriedades comuns, que determinam a associação de um *pixel* à uma região podem ser textura, cor, intensidade do nível de cinza ou outra que satisfaça os requisitos da aplicação. Por exemplo, Jan (2006) sugere como um quesito de semelhança o módulo da diferença entre as intensidades de nível de cinza: se esse módulo se encaixar em determinado intervalo, o *pixel* é agregado à região.

Este método é inerentemente *bottom-up*, pois, a partir de um *pixel* (nível baixo de abstração), agrega *pixels* da vizinhança e assim obtém elementos mais complexos (nível alto de abstração) (RUSS, 2007). Apesar da forma intuitiva deste método, há dois pontos quanto ao método que devem ser considerados: a seleção das sementes e o quesito utilizado como regra de similaridade. A determinação das sementes (seu posicionamento na imagem) depende da natureza da aplicação e do tipo de imagem utilizado. A regra de similaridade se relaciona de forma direta à aplicação, ou seja, dependendo da aplicação, uma determinada regra pode obter resultados relevantes enquanto outra não é capaz de identificar as regiões significativas neste contexto. O uso de imagens coloridas, por exemplo, é fundamental para obter o resultado esperado em determinadas aplicações (GONZALEZ; WOODS, 2008). A Fig. 22 apresenta um exemplo da segmentação baseada em crescimento de regiões.

O método de divisão e fusão (*Split and Merge*) possui uma abordagem *top-down* para a segmentação. O método parte da seleção de um critério de uniformidade, geralmente baseado em informações estatísticas a respeito da imagem e, da imagem como um todo, é aplicado divisões ou fusões na imagem respeitando tal critério. Para a divisão, a imagem é dividida em 4 quadrantes e o critério é reavaliado para cada um deles. Quando não é mais possível realizar divisões, o critério é reavaliado entre quadrantes adjacentes. Caso se identifique que dois quadrantes adjacentes, por exemplo, têm uniformidade suficiente, é realizada uma fusão. O algoritmo termina quando não é mais possível realizar nenhuma fusão. A Fig. 23 ilustra o funcionamento da técnica da divisão e




Figura 22: Crescimento de regiões. (a)–(d) definição de diversas sementes.
Fonte: (RUSS, 2007, p. 439)

fusão entre os quadrantes. A Fig. 23(a) apresenta as divisões da imagem em quadrantes e a Fig. 23(b) ilustra a hierarquia de divisões dos quadrantes e, conseqüentemente, a ordem em que serão processados.

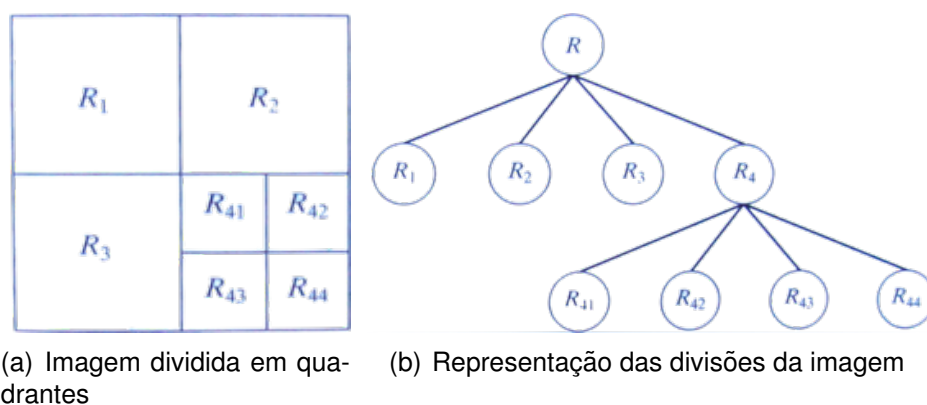


Figura 23: Divisão e fusão. Fonte: (GONZALEZ; WOODS, 2008, p. 767)

Pode-se comparar o resultados das duas metodologias na Fig. 24. Estes métodos apresentam uma vantagem importante sobre o método da limiarização: são capazes de identificar todas as regiões de uma imagem de uma vez, ao invés de aplicar o método para cada região que se deseja segmentar. Os métodos de segmentação são utilizados, naturalmente, em aplicações onde a semelhança espacial da imagem tem um papel importante. Como exemplo,

uma aplicação que identifique constelações pode utilizar a distância relativa entre corpos celestes em uma imagem como critério de similaridade.

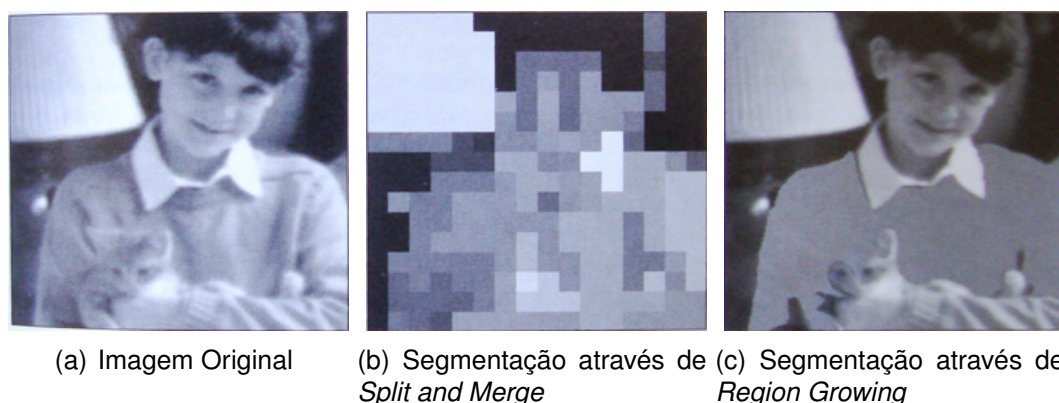


Figura 24: Segmentação por similaridade. Fonte: (RUSS, 2007, p. 437)

3.4.2 Watershed

Nesta seção é discutida a técnica de segmentação por *watershed*. Esta técnica incorpora vários conceitos dos métodos apresentados na Subseção 3.4.1 garantindo uma segmentação muitas vezes mais estável e robusta (GONZALEZ; WOODS, 2008). A técnica de *watershed* é tida como uma técnica de crescimento de regiões e é geralmente utilizada para contornar o problema que surge quando duas regiões se tocam e não podem ser separadamente identificadas, contadas ou mensuradas pelos outros métodos (RUSS, 2007).

O método foi originalmente proposto por Digabel e Lantuéjoul (1978 apud SANTOS, 2002) e elaborado posteriormente por Beucher e Lantuéjoul (1979 apud SANTOS, 2002). O conceito do método é baseado na visualização de uma imagem bidimensional em uma imagem em três dimensões: duas coordenadas espaciais e a intensidade como terceira dimensão. O conceito claramente representa um mapa topográfico onde a intensidade do *pixel* representa a altitude na posição (x, y) . A Fig. 25 ilustra essa visão.

Existem duas abordagens para implementação da técnica de *watershed*: baseada em precipitação ou em inundação (PRATT, 2007). A abordagem por precipitação caracteriza um processo *top-down* (da imagem ao *pixel*), ou seja, parte-se da imagem como um todo e em seguida é realizada a simulação dos fluxos de água da precipitação pelo caminho mais íngreme em direção a um repositório, denominado região de mínimo. O conjunto dos *pixels* que formam um caminho por onde os fluxos de água estão convergindo até uma região de mínimo é denominada *Catchment Basin*. Quando não é possível determinar que direção um fluxo escolherá a partir de um determinado *pixel*, tem-se que essa posição representa uma divisão entre dois fluxos distintos, uma barreira ou




Figura 25: Conceito de *watershed*.

Fonte: (DELEST; BONÉ; CARDOT, 2006, p. 2)

watershed line. O principal objetivo de algoritmos baseados nestes conceitos é obter as *watershed lines*, justamente as linhas que delimitam os objetos de interesse. A interpretação de cada ponto na imagem quando da execução do algoritmo pela abordagem da precipitação pode ser resumida como:

1. o ponto pertence a uma região de mínimo;
2. o ponto leva o fluxo de água a uma região de mínimo (caminho);
3. o ponto onde não é possível determinar a direção do fluxo (borda) (é igualmente suscetível escolher mais de uma região de mínimo como destino)

A outra abordagem para implementação do filtro simula uma inundação a partir do nível mais baixo, caracterizando um processo *bottom-up* (do *pixel* à imagem). O funcionamento do algoritmo nesta abordagem é análogo à uma enchente, com certas particularidades. Imaginemos que cada região de mínimo possua uma abertura por onde o fluxo de água emergiria a uma velocidade constante. Quando os fluxos de água estão prestes a se unir, uma barreira ou *watershed line* é criada para prevenir a união. A inundação prossegue até o momento em que é possível visualizar apenas as linhas divisórias, quando a inundação alcança o nível máximo correspondente ao mais alto nível de intensidade. Estas linhas são as bordas ou limites extraídos pelo algoritmo de segmentação por *watershed* (DELEST; BONÉ; CARDOT, 2006). A criação destas barreiras entre fluxos distintos através da abordagem de inundação é ilustrada na Fig. 26. A seqüência apresentada nas Figs. 26(a) a 26(d) ilustra a criação das barreiras, denominadas linhas divisórias ou *watershed lines*, até que o fluxo de água (cinza) atinja uma determinada altura.

Uma das principais aplicações da segmentação por *watershed* é a extração de objetos uniformes em uma imagem. O algoritmo é geralmente aplicado à




Figura 26: Barreiras entre fluxos distintos (*watershed lines*) (a)–(d) Crescimento do fluxo e criação das barreiras.

Fonte: (DELEST; BONÉ; CARDOT, 2006, p. 2)

imagens de gradiente, ao invés da imagem original. As pequenas variações de intensidade possuem baixo valor de gradiente. Nesta abordagem a região de mínimo se relaciona a valores pequenos de gradiente, caracterizando os objetos de interesse. A execução da técnica de *watershed* pode ser acompanhada através da Fig. 27. A Fig. 27(a) ilustra a imagem original e a Fig. 27(b) ilustra a representação topográfica. As Figs. 27(c) a 27(g) ilustram os vários estágios de inundação onde o tom cinza claro representa a água. Pode-se notar na Fig. 27(f) que os fluxos de água estão prestes a se fundir e na Fig. 27(g) são criadas barreiras para impedir a fusão destes fluxos (linhas finas). Finalmente, a Fig. 27(h) apresenta o resultado da segmentação sobrepondo as barreiras criadas sobre a imagem original e assim delimitando as regiões.

Dois problemas inerentes a esta técnica são *under segmentation* e *over segmentation*. *Under segmentation* diz respeito a baixa quantidade de regiões detectadas pela aplicação da técnica enquanto *over segmentation* diz respeito a detecção excessiva de regiões pela técnica. Ambos problemas são dependentes dos parâmetros utilizados pelo filtro, como o nível que determinará a fusão de regiões e o nível máximo de inundação. A aplicação é de fundamental importância no tratamento destes problemas, o que leva à definição dos parâmetros. Portanto, se faz necessário que os parâmetros sejam bem mensurados no contexto da aplicação alvo. Este processo geralmente é realizado através

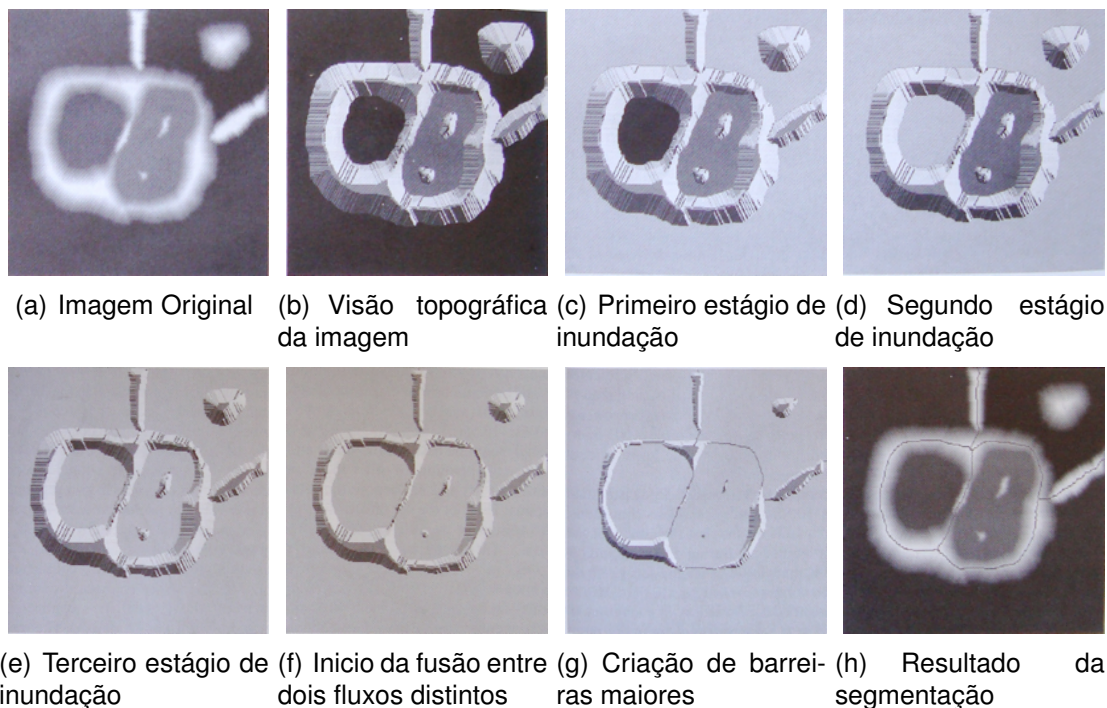


Figura 27: Execução do *watershed*.

Fonte: (GONZALEZ; WOODS, 2008, p. 770 e 771)

de tentativa e erro, como nota Ibáñez et al. (2005), pois a constituição estrutural da imagem influencia fortemente no resultado da aplicação do algoritmo de *watershed*.

3.5 Síntese do Capítulo

O capítulo apresentou a base teórica essencial para a compreensão deste trabalho. Deu-se a apresentação da área de processamento de imagens, relacionando as diversas metodologias e classificações da área e suas relações. Em seguida foram apresentadas sucinta e brevemente os conceitos de processamento de imagens envolvidos no trabalho.

Adquiriu-se assim, conhecimento sobre as operações realizadas neste trabalho, deste as operações básicas entre imagens, aplicação de filtros de borrramento e de realce até o funcionamento de algoritmos de segmentação de imagens. Nesta última categoria, dá-se especial atenção ao algoritmo de segmentação de imagens baseado na técnica de *watershed* que é o foco deste trabalho.

4 FERRAMENTA DESENVOLVIDA

Este capítulo apresenta a ferramenta desenvolvida. A ferramenta objetiva auxiliar no processo de diagnóstico de neuropatologias através da segmentação semiautomática do volume encefálico global em imagens de ressonância magnética. São apresentadas as bibliotecas e linguagem utilizadas, a metodologia utilizada para a concepção da ferramenta além funcionamento da mesma, destacando alguns aspectos da implementação.

4.1 Materiais

Esta seção trata dos materiais utilizados. A saber: os equipamentos e sistemas operacionais utilizados, a linguagem utilizada, as bibliotecas e filtros utilizados e, finalmente as imagens volumétricas utilizadas para avaliação da ferramenta.

4.1.1 Equipamento e Sistema Operacional

O sistema operacional utilizado para o desenvolvimento foi o Mac OS X 10.5.5 (*Leopard*) sobre um computador Apple Macbook com as seguintes especificações:

- Processador Intel Core 2 Duo 2.0 GHz;
- 2 GB de RAM;
- placa de vídeo integrada Intel GMA 950 com até 64 MB compartilhados;

Entretanto, a avaliação da ferramenta através de simulações foi realizada em ambiente GNU/Linux (Ubuntu 8.10), um sistema operacional livre, *open-source* e distribuído gratuitamente. As especificações da máquina utilizada para as simulações são:

- Processador Intel Core 2 Duo E6750 2.66 GHz;

- 4 MB memória *cache*;
- 1GB de RAM;

Vale ressaltar que não houve alterações no código entre o desenvolvimento e a avaliação da ferramenta (entre plataformas diferentes).

4.1.2 Linguagem de Desenvolvimento

A ferramenta foi desenvolvida utilizando a linguagem de programação C++. A linguagem C++ foi desenvolvida originalmente como uma extensão para a linguagem C, adicionando alguns recursos como suporte a orientação a objetos e tratamento de exceções. Essa linguagem teve origem no *Bell Laboratories* (BELL, 2008), no início dos anos 80, por Bjarne Stroustrup (DEITEL, 2005). A linguagem proporciona um alto nível de abstração, sistema de tipos estático e permite a programação em múltiplos paradigmas, incluindo programação procedural, genérica e orientada a objetos. Uma das características mais interessantes da linguagem e amplamente utilizada é o suporte a *templates*. *Templates* são uma forma de programação genérica, onde o código gerado pode ser parametrizado. Isso é possível através da abstração de dados e da sobrecarga de operadores suportada pela linguagem. As bibliotecas utilizadas são desenvolvidas sobre esta linguagem, proporcionando um alto desempenho e a possibilidade de reuso de código. Além disso, a linguagem tem o intuito de ser portátil, fazendo com que os códigos gerados sejam utilizados nos mais diversos sistemas sem a necessidade de alteração.

4.1.3 Bibliotecas Gráficas

Fazemos uso das diversas técnicas de processamento de imagens para atingir o objetivo do trabalho. O desenvolvimento baseou-se no uso de uma biblioteca de processamento de imagens que provê uma grande quantidade de código validado e testado. A biblioteca foi analisada e as rotinas que apresentavam o funcionamento desejado foram avaliadas, testadas e aplicadas no desenvolvimento da ferramenta. A biblioteca de processamento de imagens é o tópico desta seção.

4.1.3.1 *Insight Toolkit - ITK*

O trabalho faz uso da biblioteca ITK (*Insight Segmentation and Registration Toolkit*) (IBÁÑEZ et al., 2005), um conjunto *open-source* de algoritmos e estruturas para registro (encontrar correspondência entre dados) e segmentação de imagens. A biblioteca é implementada em C++, utiliza a ferramenta de compilação CMake (CMAKE, 2008) e é independente de plataforma. Além

disso, a biblioteca disponibiliza uma série de interfaces para outras linguagens de programação como Tcl, Java e Python, permitindo que programadores produzam usando um grande variedade de linguagens de programação. A implementação em C++ da biblioteca é baseada em programação genérica, utilizando o suporte à *templates* da linguagem. Esse modelo de programação permite que o mesmo código possa ser utilizado genericamente para qualquer classe ou tipo que suporte as operações utilizadas e, além disso, faz com que o código seja altamente eficiente e que problemas sejam encontrados em tempo de compilação, ao invés da detecção apenas em tempo de execução. Como se trata de um projeto *open-source*, qualquer desenvolvedor pode fazer uso, depurar, manter e estender o *software* (IBÁÑEZ et al., 2005).

O ITK é mantido pelas instituições: Kitware, GE Corporate R&D, Insightful, University Chapel Hill, University of Utah e University of Pennsylvania, sendo que as três primeiras são mantenedoras comerciais e as demais são instituições acadêmicas (KITWARE, 2008). A biblioteca tem foco em aplicações médicas, embora não haja restrições quanto ao processamento de outros tipos de dados (ZANCHET, 2007). Foi utilizada a versão 3.8 pra o desenvolvimento e a versão 3.10 para as avaliações.

4.1.4 Filtros Utilizados

Esta subseção apresenta as classes da biblioteca que implementam os filtros utilizados no desenvolvimento do trabalho. Diversos filtros foram testados; os que apresentam os melhores resultados no contexto da aplicação foram adotados e são detalhados abaixo.

4.1.4.1 Borramento Preservando Bordas

As bordas de objetos, quando da aplicação de um filtro de borramento, são mescladas à vizinhança, dificultando a distinção entre elementos relevantes como estruturas anatômicas em uma imagem médica. Mesmo quando o filtro de borramento não afeta tão significativamente as bordas, ele pode fazer com que pequenos detalhes se percam.

Perona e Malik (1990) apresentaram uma alternativa aos filtros lineares que foram então chamados de filtros de borramento anisotrópicos. Borramento anisotrópico é altamente relacionado ao trabalho de Grossberg (1984 apud IBÁÑEZ et al., 2005), que utiliza um processo similar de borramento não-linear para modelar a visão humana. A motivação desta espécie de filtro, conhecidos também como filtros não-uniformes ou borramento de condutância variável, é aplicar um borramento mantendo a constituição estrutural da imagem. Este tipo de filtro depende de uma variável, a condutância, que por sua vez é dependente

da estrutura da imagem (bordas, essencialmente). A condutância serve, assim, para limitar o borramento em bordas da imagem. Nota-se assim a importância dessa espécie de filtro para aplicações de segmentação de imagens onde é necessário preservar a estrutura dos elementos.

A biblioteca ITK define diversos filtros de borramento baseados nestes princípios, alterando a forma como se realiza o borramento ou como se limita o borramento de bordas. O filtro escolhido para utilização no desenvolvimento foi o filtro *Curvature Anisotropic Diffusion* por apresentar os melhores resultados quanto à preservação de borda e borramento uniforme. Este filtro aplica o borramento anisotrópico à imagem utilizando uma equação modificada de borramento de curvatura (MCDE) (IBÁÑEZ et al., 2005). Essa equação não possui propriedades para realce de bordas, como em algumas implementações de filtros anisotrópicos, mas em certas condições pode gerar o realce no contraste destas.

Este filtro requer três parâmetros: a quantidade de iterações que devem ser realizadas, o passo utilizado na MCDE para o cálculo do nível de saída e a condutância. Estes parâmetros podem ser definidos através dos métodos `SetNumberOfIterations()`, `SetTimeStep()` e `SetConductance()`, respectivamente. No desenvolvimento optou-se pela utilização destes parâmetros definidos diferentemente dos usuais 0.0625, 5 e 3 para o passo em imagens tridimensionais, a quantidade de iterações e a condutância, respectivamente (IBÁÑEZ et al., 2005). Essa definição baseou-se em testes dos parâmetros e seu resultado quanto à quantidade de borramento e a preservação das bordas, primando sempre pela qualidade do resultado. A saber:

- Passo: 0.0625. Valor tipicamente usado para este parâmetro em volumes (imagens tridimensionais)
- Iterações: 10. Foi utilizado uma quantidade um pouco maior de iterações para garantir um borramento maior em áreas homogêneas
- Condutância: 10. Novamente foi utilizado um valor superior ao usual para garantir a preservação das bordas com maior nitidez

A Fig. 28 exemplifica o resultado da aplicação do filtro a uma imagem de RM utilizando como parâmetros 0.125, 5 e 3 para o passo, a quantidade de iterações e a condutância, respectivamente. Os parâmetros utilizados neste caso são os usuais para imagens bidimensionais (IBÁÑEZ et al., 2005). Pode-se notar que o filtro, mesmo borrando as áreas homogêneas, é capaz de preservar as bordas e assim manter a constituição estrutural da imagem praticamente intacta.




Figura 28: Filtro de borramento preservando bordas.

Fonte: (IBÁÑEZ et al., 2005, p. 199)

4.1.4.2 Realce de Bordas

Um das operações mais comuns em processamento de imagens é o cálculo de gradientes, ou seja, o realce de bordas através da diferenciação espacial. O termo gradiente é utilizado pois o realce é garantido através do cálculo da magnitude do gradiente obtida através de derivadas de primeira ordem. A magnitude do gradiente é amplamente utilizada para realce de bordas (IBÁÑEZ et al., 2005).

Um dos filtros utilizados para realce de bordas é o filtro de magnitude de gradiente implementado pela classe *Gradient Magnitude*. Este filtro calcula a magnitude do gradiente para cada *pixel* utilizando diferenciação. O filtro de gradiente é utilizado para realce de transições suaves de intensidade e é sensível à ruído, como pode ser visto na Fig. 29 que ilustra a aplicação do filtro a uma imagem de ressonância magnética.




Figura 29: Filtro de realce de bordas (gradiente).

Fonte: (IBÁÑEZ et al., 2005, p. 154)

Derivadas de segunda ordem são utilizadas para realçar transições bruscas de intensidade. O filtro utilizado para o realce de transições bruscas foi o filtro LaplacianSharpening. Esse filtro aplica as máscaras *Laplacianas* sobre a imagem, realçando assim as bordas onde há transições de intensidade de forma abrupta.

4.1.4.3 Adição e Inversão

Para incorporar o realce das bordas à imagem original é utilizada a adição entre imagens. Essa adição foi realizada para que os resultados dos filtros de gradiente e *laplaciano* sejam intensificados na imagem original. O filtro utilizado para adição é o Add Image Filter. Este filtro tem como entrada duas imagens e gera a adição destas.

Além do filtro de adição, é requerido a inversão da imagem, isto é, que as altas intensidades fossem transformadas em baixas e vice-versa. Essa inversão visa, como as etapas anteriores, fazer com que o filtro de *watershed* obtenha um melhor resultado. A inversão faz com que o que representa vales na imagem original, represente montanhas e vice-versa, destacando as estruturas relevantes. O filtro utilizado para inversão da imagem é o Invert Intensity Image Filter.

4.1.4.4 Watershed

O filtro de *watershed* implementado na biblioteca (Watershed Image Filter) utiliza a abordagem da simulação de chuva em um relevo (representação da imagem). O filtro tem o seguinte funcionamento: imagine que a queda de água sobre um relevo que é definido pelas intensidades da imagem (alta intensidade representam montanhas enquanto baixas intensidades representam vales). A medida que chove, a gravidade faz com que os fluxos de água se dirijam a regiões de baixa altitude. O tamanho destas regiões cresce com o aumento da precipitação até que estejam prestes a se unir. As regiões de mínimo, como são chamadas, podem aumentar de tamanho através da mescla de duas regiões vizinhas, caso os parâmetros do filtro permitam tal processo.

A técnica de *watershed* é flexível, visto que não gera apenas uma imagem segmentada, mas uma hierarquia de imagens de onde alguma região ou grupo de regiões pode ser extraído (IBÁÑEZ et al., 2005). O processo classifica os *pixels* que dirigem o fluxo de água a uma região de mínimo como pertencentes à mesma. Na prática este processo gera uma região para cada região de mínimo, claramente uma situação de *over segmentation* (pois gera muitas regiões). Para aliviar este problema, pode-se definir uma profundidade mínima para o *watershed*. A profundidade do *watershed* é a diferença em altura entre a região

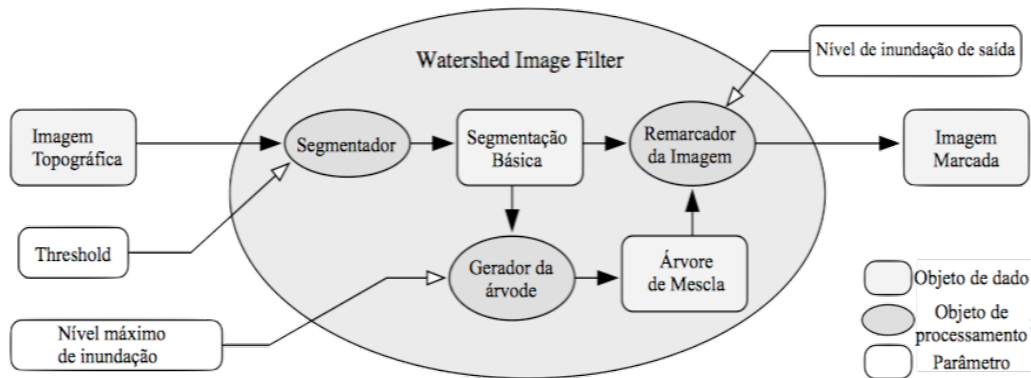


Figura 30: Implementação do *watershed* no ITK.
Adaptado de: (IBÃNEZ et al., 2005, p. 526)

de mínimo e o ponto mais baixo que representará uma borda. Esta profundidade representa a profundidade máxima para que uma região de mínimo não se una à uma região vizinha. Assim, o filtro mescla regiões de mínimo até que a profundidade definida seja alcançada.

A Fig. 30 ilustra o filtro implementado na biblioteca. Pode-se notar que o filtro é dependente de três parâmetros: um limiar (*threshold*) inicial, o nível máximo de precipitação e o nível de precipitação de saída. O nível de precipitação de saída é utilizado para determinar qual nível da hierarquia de regiões geradas será a saída. Os outros dois parâmetros influenciam o funcionamento do filtro e portanto seu resultado. É válido destacar que a definição destes dois parâmetros é dependente do contexto da aplicação. A calibragem destes parâmetros é um processo de tentativa e erro (IBÃNEZ et al. 2005). Estes dois parâmetros são definidos pelos métodos: `SetLevel()` para definir a profundidade do *watershed* (Level) e `SetThreshold()` para definição da limiarização mínima da entrada (Threshold). A saída do filtro é uma imagem com as regiões demarcadas: cada região é representada por um valor determinado de intensidade, no caso são utilizados `unsigned longs`. Os parâmetros são normalizados (0 – 1), definidos como porcentagem da profundidade máxima da imagem.

O parâmetro `Threshold` pode ser utilizado para controlar o problema de *over segmentation* pois está diretamente relacionado com o tamanho inicial das regiões. Geralmente, aumentar o valor deste parâmetro faz com que o tempo de computação diminua pois o filtro será aplicado a partir de uma altura inicial de água maior. Essa alteração produz uma saída com menos regiões e regiões maiores. A idéia para definir estes parâmetros é utilizar a escala de intensidade dos objetos que se deseja segmentar.

É importante notar, como destacado por Ibãnez et al. (2005), que a complexidade do filtro se baseia na geração da hierarquia. O processamento para essa etapa é não-linear em relação a quantidade de regiões de mínimo

na segmentação inicial. Percebe-se assim que a quantidade de informação presente na imagem é mais importante que apenas a quantidade de *pixels* da mesma. Uma imagem grande mas com poucos detalhes é processada de forma rápida pelo filtro, enquanto uma imagem pequena mas cheia de detalhes demanda um tempo maior para ser processada.

4.1.5 Imagens Utilizadas

As imagens utilizadas durante o desenvolvimento da ferramenta e para simulação e definição do intervalo relevante de parâmetros foram obtidas em dois repositórios principais: a tese de doutorado do Professor Dr. Lucas Ferrari de Oliveira (2005) e de um repositório aberto de imagens médicas para fins educacionais disponibilizado pelo Departamento de Radiologia do Hospital Universitário de Genebra (*Hôpitaux Universitaires de Genève (HUG)*), Suíça (CASIMAGE, 2008). Outro repositório analisado foi o *Medical Imaging*, disponibilizado por Barré (2008). Para o desenvolvimento e teste da ferramenta foi utilizado cerca de 20 imagens, sendo a maioria imagens tridimensionais (volumes) e a minoria imagens bidimensionais.

4.2 Métodos

4.2.1 Considerações quanto ao problema

O problema de segmentação do volume cerebral de imagens de ressonância magnética foi analisado e algumas considerações puderam ser formuladas quanto aos métodos utilizadas:

1. o método de segmentação deve ser robusto
2. a formação estrutural do volume deve ser preservada
3. a qualidade da segmentação deve ser garantida
4. máxima automatização do processo

Com base nestas considerações, as técnicas de processamento de imagens foram estudadas visando encontrar uma solução plausível ao problema. Deste estudo, foi desenvolvido um *pipeline* de processamento capaz de segmentar o volume cerebral de forma semiautomática. Este *pipeline* é alvo da próxima Seção (4.2.2), onde as várias etapas desenvolvidas são explanadas.

4.2.2 Pipeline de Processamento

A partir das considerações feitas, os filtros da biblioteca ITK foram organizados em uma série de etapas para alcançar o resultado desejado. A Fig. 31

ilustra o *pipeline* de execução desenvolvido que tem como entrada uma imagem de ressonância magnética em formato DICOM e resulta em uma imagem que representa a delimitações das regiões. O *pipeline* aplica diversos filtros visando o borramento de estruturas não relevantes e de realce de estruturas de interesse, soma o resultado destes dois processos, realiza a inversão da imagem e, finalmente, aplica o filtro de *watershed*. As operações realizadas por este *pipeline* são resumidas abaixo:

1. aplicação do filtro de borramento para redução do ruído
2. aplicação de filtros para realce das transições
 - aplicação do filtro de gradiente para realce das transições suaves
 - aplicação do filtro *laplaciano* para realce de transições bruscas
 - adição do resultado dos filtros à imagem borrada
3. inversão da imagem
4. aplicação do *watershed*

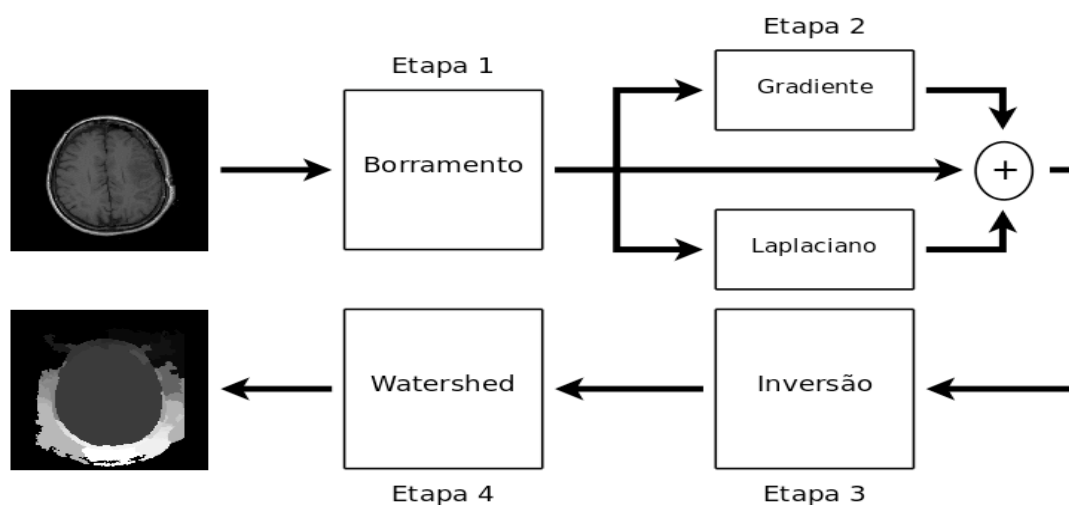


Figura 31: *Pipeline* de execução desenvolvido.

A execução da ferramenta é feita de forma relativamente simples. São passados à ferramenta como parâmetros: o nome do arquivo de entrada, opcionalmente os parâmetros para o filtro de borramento, os parâmetros para o filtro de *watershed* e o diretório que receberá o resultado da ferramenta. A imagem de entrada é uma imagem DICOM ou uma pasta com uma série DICOM. Em qualquer um dos modos, a ferramenta identifica se a entrada é um volume ou uma série de cortes e gera a representação volumétrica. Em seguida é iniciada a aplicação dos filtros, utilizando os parâmetros passados. Caso não tenham sido definidos pelo usuário, os parâmetros são definidos com os valores padrão:

- Passo: 0.0625.
- Iterações: 10.
- Condutância: 10.

Os valores do *watershed* são dependentes da aplicação e se faz necessária uma simulação para determinação do intervalo relevante para o caso da segmentação do volume encefálico global. As imagens utilizadas nesta seção são exemplos da execução da ferramenta sobre um imagem DICOM utilizando os parâmetros padrão e os parâmetros de *watershed* (Level=0.3 e Threshold=0.3).

A primeira etapa da ferramenta é a leitura da imagem DICOM e aplicação do filtro de borramento. Este processo é ilustrado pela Fig. 32. É possível perceber a diminuição do ruído da imagem enquanto que as bordas são preservadas através da aplicação de um filtro de borramento que preserve as bordas. Isto é fundamental para manter a constituição estrutural da imagem, item 2 das considerações.




Figura 32: Etapa 1 do *pipeline* de execução - borramento.

Em seguida são aplicados ambos filtros de detecção de bordas. O filtro de gradiente é aplicado para realçar as transições suaves enquanto o filtro *laplaciano* é utilizado para destacar as transições bruscas de intensidade. O resultado da detecção das bordas é somado à imagem de borramento, fazendo com que seja gerada uma imagem com o ruído reduzido e as transições destacadas (tanto as transições suaves como as bruscas). O realce das bordas é essencial para a identificação estrutural da imagem, delimitando regiões de interesse. Pode-se notar, por exemplo, que o encéfalo é delimitado através de uma transição na intensidade que deve ser destacada. A Fig. 33 apresenta a realização desta etapa.




Figura 33: Etapa 2 do *pipeline* de execução - realce de bordas.

O próximo passo é realizar a inversão da imagem. A inversão da imagem diz respeito a tornar os valores altos (claros) em baixos (escuros) e vice-versa. Esta inversão de valores faz com que a representação em relevo da imagem, importante para a etapa do *watershed*, também seja invertida: o que representava montanhas agora representa vales e vice-versa. Pode-se perceber que a delimitação das estruturas apresenta um resultado melhor com a inversão, pois valores extremamente altos (branco) representam montanhas de mesma altura e assim restringem os fluxos de água. Novamente, o limite do encéfalo é caracterizado dessa forma, como pode ser visto na Fig. 34.

Finalmente, a próxima etapa é a aplicação do *watershed* à imagem invertida. O filtro de *watershed* implementado utiliza a abordagem da simulação de precipitação em um relevo (representação tridimensional da imagem). A aplicação do filtro faz com que as regiões cresçam com o aumento da precipitação, até que estas estejam prestes a se unir. As regiões de mínimo podem aumentar de tamanho através da mescla de duas regiões vizinhas, caso os parâmetros do filtro permitam tal processo. O processo classifica os *pixels* do caminho de um fluxo de água a uma região de mínimo como pertencentes a uma mesma região. O processo termina quando o nível de precipitação atinge um limiar




Figura 34: Etapa 3 do *pipeline* de execução - inversão da imagem.

definido pelos parâmetros. As regiões delimitadas por esta etapa são marcadas através de cores: uma região possui o mesmo tom-de-cinza. O resultado da segmentação semiautomática pode ser visto na Fig. 35, onde a Fig. 35(a) ilustra a imagem resultante da etapa de inversão e a Fig. 35(b) ilustra o resultado da aplicação do filtro de *watershed* sobre esta imagem.

É possível perceber que a ferramenta foi capaz de identificar corretamente o volume cerebral. O conjunto de imagens utilizado para exemplificar esta seção apresenta apenas uma fatia da imagem de teste. É notável como a formação estrutural da imagem influencia na técnica de *watershed*. Na Fig. 35 pode-se perceber esta influência na região do crânio e no espaço entre o mesmo e o volume cerebral.




Figura 35: Etapa 4 do *pipeline* de execução - *watershed*.

5 RESULTADOS OBTIDOS

5.1 Simulações

Uma série de imagens obtidas do trabalho de Oliveira (2005) foram utilizadas para a avaliação da ferramenta. Foi desenvolvido um *script* em *Shell Script* (JARGAS, 2008) para a simulação da ferramenta. Esse *script* foi utilizado para executar a ferramenta 300 vezes. Cada execução usou um conjunto de parâmetros diferente: variou-se os parâmetros do *watershed* de 0.1 a 1.0 (10% a 100%). A Fig. 36 exemplifica a simulação da ferramenta com parâmetros: *Level*=30% e *Threshold*=30% (apenas um corte do volume). Pode-se notar que a ferramenta foi capaz de identificar corretamente o volume encefálico, porém com algumas estruturas extras.

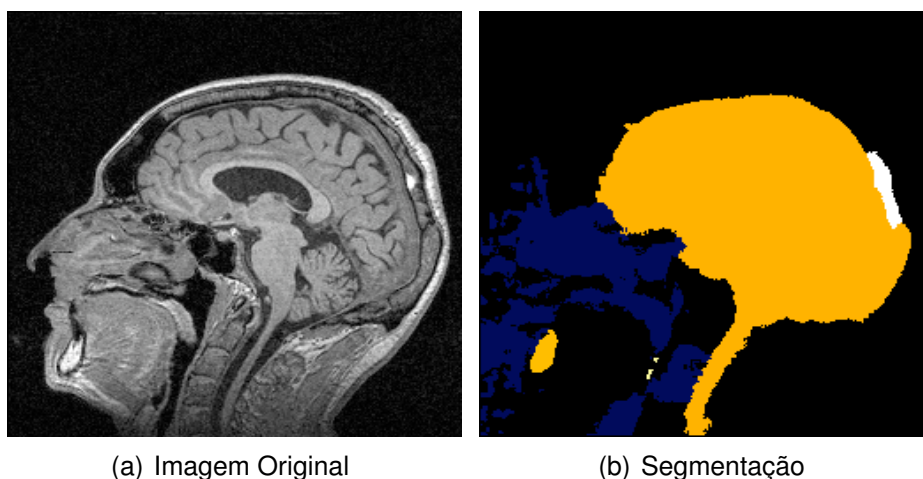


Figura 36: Resultado da ferramenta - cortes.

Além disso, foram utilizados como base os três planos, ou seja, foram gerados os volumes a partir de cada plano (Axial, Sagital e Coronal) e estes utilizados na simulação. O teste foi realizado para cada plano para verificar se este fator tem influencia no resultado. A totalização das simulações é representada pela execução do intervalo de parâmetros para cada representação (com passo de 10%):

Axial 10% a 100% para cada parâmetro (100 execuções)

Sagittal 10% a 100% para cada parâmetro (100 execuções)

Coronal 10% a 100% para cada parâmetro (100 execuções)

Total 300 execuções

5.2 Considerações

Os resultados permitiram identificar o intervalo de valores relevantes à ferramenta. Este intervalo representa o conjunto de valores que não geram *under segmentation* ou *over segmentation*. Valores de Level maiores que 40% ou valores de Threshold maiores que 95% fazem com que o resultado comece a apresentar o problema de *under segmentation*. O problema de *over segmentation* não foi apresentado pelo intervalo de parâmetros utilizados na aplicação de segmentação do volume cerebral. Nas Figs. 37 e 38 é possível perceber o resultado da ferramenta de forma volumétrica (utilizando o *software* ImageJ (RASBAND, 2008)). A Fig. 37 apresenta o volume de entrada e a Fig. 38 apresenta o volume encefálico detectado.




Figura 37: Volume de entrada. Visualizado através do *software* ImageJ.

É importante notar que, apesar da ferramenta detectar claramente o volume encefálico, testes mais extensivos e uma avaliação clínica real (por um especialista) deve ser realizada. O método é robusto: mesmo que a imagem possua

pequenas variações na anatomia cerebral, a ferramenta é capaz de detectá-lo, mesmo incluindo estruturas extras.

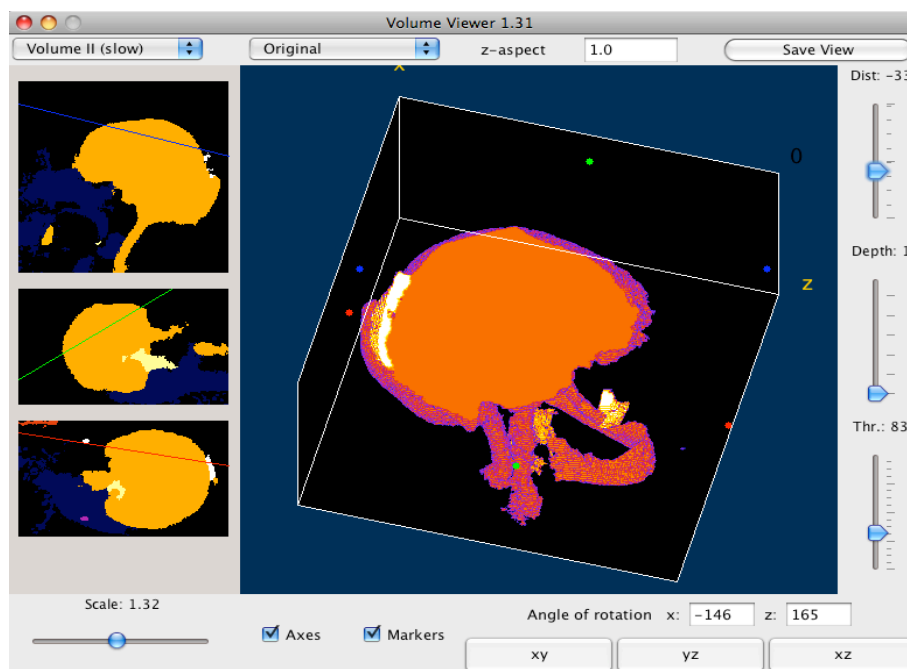


Figura 38: Volume detectado. Visualizado através do *software* ImageJ.

Outro ponto válido é a avaliação quanto ao tempo de execução. A ferramenta levou, em média, 7 minutos para segmentar um volume cerebral. Acredita-se que o tempo de execução possa ser reduzido levando em consideração os parâmetros utilizados para o filtro de borrimento. Como se trata de um filtro de borrimento preservando bordas, o aumento da quantidade de iterações e a força da restrição do borrimento nas bordas afeta significativamente o tempo de execução. Entende-se que a diminuição da quantidade de iterações e da força de restrição de borrimento nas bordas não afetará significativamente o resultado da segmentação, mas poderá reduzir o tempo de execução aproximadamente pela metade. A confirmação destas hipóteses é tida como um trabalho futuro, visando a preparação de uma publicação.

6 CONSIDERAÇÕES FINAIS

O presente trabalho propôs o desenvolvimento de uma ferramenta para segmentação semiautomática do volume encefálico global em imagens de ressonância magnética. A proposta baseou-se em técnicas de processamento de imagens, como filtros de suavização, de gradiente e a técnica de *watershed*. O desenvolvimento foi realizado com a biblioteca de processamento de imagens ITK.

A análise das imagens provenientes de exames de ressonância magnética é feita comparando-se, lado a lado, imagens impressas em filmes radiográficos que representam cortes de todo o exame analisado. Fica claro a necessidade de desenvolvimento de ferramentas computadorizadas para o auxílio neste processo de diagnóstico. Existem softwares proprietários que realizam diversas tarefas, tais como alinhamento, marcação de regiões de interesse (ROIs), tratamento de imagens e segmentação, mas as técnicas mais utilizadas para segmentação nestes *softwares* envolve a interação do especialista, portanto são semiautomáticas.

São diversos os fatores que influenciam no processo de diagnóstico. Por exemplo, a interação do especialista afeta o processo de diagnóstico na medida em que, da análise de diversos cortes diferentes do exame, pode-se obter conclusões diferentes. Assim sendo, percebe-se que a marcação manual das regiões de interesse é um processo trabalhoso e cansativo, e que apresenta limitações quanto à reprodutibilidade dos estudos pois exige, por parte do especialista, conhecimentos prévios de neuroanatomia e destreza motora (MOREIRA, 2004 apud MILANI, 2007).

Um processo automatizado de segmentação se faz necessário neste caso. O objetivo da automatização é auxiliar no processo quantitativo de diagnóstico. A segmentação de uma imagem é fundamental para seu entendimento. Este processo tem por objetivo destacar as regiões de interesse em um determinado contexto (aplicação). Este processo é natural ao ser humano, mas não aos computadores. O cérebro humano é capaz de reconhecer objetos assim que

os vê, interpretando e combinando informações obtidas pelo sistema visual de modo paralelo.

As técnicas e ferramentas existentes que utilizadas para a segmentação do volume cerebral apresentam dois poréns: ou são proprietárias ou utilizam uma técnica cujo resultado possa ser melhorado. Logo, o trabalho propõe o desenvolvimento de uma ferramenta *open-source* visando a identificação semiautomática do volume encefálico global utilizando uma técnica diferente da usual: a técnica de *watershed*. Nesta técnica a imagem é interpretada como uma superfície topográfica, onde os níveis de cinza representam as altitudes dos vales e montanhas. É realizada a inundação desta superfície até que áreas com fluxos de água distintos estão prestes a se fundir, então é construída uma barragem sobre a superfície mais alta para prevenir a fusão dos fluxos de água. Finalmente, as únicas coisas visíveis da superfície serão as barragens. Estas barragens são chamadas de *watershed lines* e representam contornos de áreas distintas da imagem. Esta técnica é diretamente dependente da estrutura da imagem e, portanto, apresenta resultados melhores que outras técnicas quando a segmentação é feita com base na estrutura da imagem.

6.1 Conclusões

O desenvolvimento da ferramenta proposta para segmentação semiautomática do volume encefálico global em imagens de ressonância magnética fez uso de técnicas de processamento de imagens como filtros de suavização e de gradiente para realçar detalhes relevantes para a aplicação e a técnica de *watershed* para segmentação. O desenvolvimento aproveitou a biblioteca de processamento de imagens *Insight Toolkit* (ITK) para a etapa de processamento. Assim, foi possível aumentar a produtividade e confiança do código gerado, haja vista que a biblioteca disponibiliza códigos de alto desempenho já testados e validados. Uma desvantagem quanto à biblioteca é a metodologia de desenvolvimento utilizada. O ITK utiliza *Extreme Programming* e, portanto, tem um ciclo de desenvolvimento mais curto e não gera muita documentação quanto às classes. A falta ou precariedade de documentação para uma biblioteca deste porte torna a curva de aprendizado muito alta, dificultando e retardando a produção de código executável.

A ferramenta foi aplicada a imagens de estudo, obtidas da tese de doutorado do Professor Dr. Lucas Ferrari de Oliveira (OLIVEIRA, 2005) e do Departamento de Radiologia do Hospital Universitário de Genebra (CASIMAGE, 2008). A simulação da ferramenta com o intuito de verificar o intervalo válido de parâmetros para o *watershed* foi realizada com sucesso e apresentou resultados

interessantes: valores de *Level* maiores que 40% ou valores de *Threshold* maiores que 95% fazem com que o resultado comece a apresentar o problema de *under segmentation*, o problema de *over segmentation* não foi apresentado e o volume pôde ser identificado na maioria dos casos.

Pôde-se notar claramente a eficácia da técnica de *watershed* para a aplicação em segmentação semiautomática do volume encefálico global através dos volumes gerados. A ferramenta foi capaz de detectar o volume cerebral na maior parte dos casos, mesmo que em alguns tenham incluído estruturas extras. Acredita-se que refinamentos na ferramenta, tanto através de testes mais extensivos com parâmetros como aplicação de algum filtro extra, possa eliminar estas estruturas que não fazem parte do volume encefálico.

6.2 Trabalhos Futuros

O trabalho será aperfeiçoado após sua conclusão visando a geração de uma publicação em evento internacional. As seguintes etapas devem ser desenvolvidas com este objetivo:

- cálculo de volume detectado
- testes extensivos quanto à precisão da técnica, comparando com volume calculado
- testes clínicos reais (em parceria com a Universidade de São Paulo)
- avaliação em relação ao desempenho da técnica
- avaliação quanto ao tempo de execução
- comparação com ferramentas comerciais, destacando as técnicas utilizadas e os resultados gerados

REFERÊNCIAS

ACR. **American College of Radiology**. Endereço eletrônico: <http://www.acr.org/>
Último acesso em: 20/11/2008.

BARRÉ, S. **Medical Imaging**. Endereço eletrônico:
<http://www.barre.nom.fr/medical/index.html> Último acesso em: 24/11/2008.

BARROS, R. C. **Desenvolvimento de Ferramenta para Análise Quantitativa de Imagens de Cintilografia de Perfusão Miocárdica através de Técnicas de Processamento de Imagens**. 2007. 85p.

BELL. **Alcatel-Lucent**. Endereço eletrônico: <http://www.alcatel-lucent.com/wps/portal/BellLabs> Último acesso em: 20/11/2008.

BEUCHER, S.; LANTUÉJOU, C. Use of Watersheds in contour detection. In: 1979, Rennes. **Anais...** International Workshop on Image Processing: Real-Time Edge and Motion Detection/Estimation, 1979.

CASIMAGE. **Casimage: Imagery Teaching Files Database**. Endereço eletrônico: <http://pubimage.hcuge.ch:8080/> Último acesso em: 24/11/2008.

CENTENO, T. M. **Processamento de Imagens**. Endereço eletrônico:
<http://www.cpgei.cefetpr.br/mezzadri/PDI/PDI.html> Último acesso em: 16/11/2008.

CLUNIE, D. A. **DICOM Structured Reporting**. Bangor, Pennsylvania: PixelMed, 2000.

CMAKE. **CMake, the cross-platform, open-source build system**. Endereço eletrônico: <http://www.cmake.org/> Último acesso em: 20/11/2008.

CONCI, A.; AZEVEDO, E.; LETA, F. R. **Computação Gráfica**. Rio de Janeiro: Elsevier, 2008. v.2.

DEITEL, H. M. **C++ How to Program**. 5.ed. [S.l.]: Prentice Hall, 2005. 1536p.

DELEST, S.; BONÉ, R.; CARDOT, H. 3D Watershed Transformation on Connected Vertices Structure. In: INTERNATIONAL WORKSHOP ON IMAGE PROCESSING, REAL-TIME EDGE AND MOTION DETECTION/ESTIMATION, 2006, Tours, France. **Anais...** Forum de l'Ecole Doctorale (Santé: Sciences: Technologies), 2006.

DICOM. **Dicom Imaging and Communications in Medicine**. Endereço eletrônico: <http://dicom.nema.org/> Último acesso em: 20/11/2008.

DICOM. **Dicom Imaging and Communications in Medicine: Strategic Document**. [S.l.]: Medical Imaging Technology Alliance, 2008.

DIGABEL, H.; LANTUÉJOUL, C. Iterative algorithms. In: FORUM DE L'ECOLE DOCTORALE (SANTÉ, SCIENCES, TECHNOLOGIES), 1978, Caen. **Anais...** Actes du Second Symposium Européen d'Analyse Quantitative des Microstructures en Sciences des Matériaux: Biologie et Médecine - Riederer Verlag: Stuttgart, 1978. p.85–99.

DINIZ, P. R. B.; SANTOS, A. C. dos; JÚNIOR, L. O. M. Comparação entre Algoritmos Computacionais para Medida de Volume Encefálico Global e Volumes Intracranianos por Segmentação Automática. In: REVISTA ELETRÔNICA DE INICIAÇÃO CIENTÍFICA REIC, 2007. **Anais...** Sociedade Brasileira de Computação, 2007. n.1. (Ano VII, v.23).

FACON, J. **Processamento e Análise de Imagens**. 2005. 119p. Dissertação (Mestrado em Ciência da Computação) — Pontifícia Universidade Católica do Paraná. Curso de Mestrado em Informática Aplicada.

FILHO, K. **Fundamentos de Radiodiagnóstico por Imagem**. Endereço eletrônico: <http://www.if.ufrgs.br/ast/med/imagens/index.htm> Último acesso em: 22/11/2008.

FUJII, S. Y. **Algoritmo de Reconstrução 3D de Imagens de Medicina Nuclear Alinhadas a Exames de Ressonância Magnética para Avaliação da Extensão de Zonas Epileptogênicas**. 2006. 83p.

GOMES, V. V. **Algoritmo Computacional para Volumetria de Estruturas Cerebrais em Imagens Médicas**. 2007. 92p.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. 3.ed. Upper Saddle River, NJ 07458: Pearson Prentice Hall, 2008. 954p.

GROSSBERG, S. Neural dynamics of brightness perception: features, boundaries, diffusion, and resonance. In: SOCIEDADE BRASILEIRA DE

COMPUTAÇÃO, 1984. **Anais...** Perception and Psychophysics, 1984. v.36, n.5, p.428–456.

HAHN, H. K.; PEITGEN, H.-O. The Skull Stripping Problem in MRI Solved by a Single 3D Watershed Transform. In: PERCEPTION AND PSYCHOPHYSICS, 2000, Berlin. **Anais...** MICCAI 2000 - Springer, 2000. p.134–143.

HEYDEN, J. E. van der; CARPENDALE, M. S. T.; INKPEN, K.; ATKINS, M. S. Visual Presentation of Magnetic Resonance Images. In: MICCAI 2000 - SPRINGER, 1998, Research Triangle Park, NC. **Anais...** IEEE Symposium on Information Visualization 98, 1998. p.434–426.

IBÁÑEZ, L.; SCHROEDER, W.; NG, L.; CATES, J. **The ITK Software Guide: Updated for ITK version 2.4**. 2.ed. [S.l.]: Insight Software Consortium - Insight Segmentation and Registration Toolkit, 2005. 804p.

JAN, J. **Medical Image Processing, Reconstruction, and Restoration: concepts and methods**. 1.ed. Boca Raton, FL 33487-2742: CRC Press, 2006. 710p.

JARGAS, A. M. **Shell Script Profissional**. São Paulo: Novatec Editora, 2008. 480p.

KITWARE. **National Library of Medicine Insight Segmentation and Registration Toolkit**. Endereço eletrônico: <http://www.kitware.com/> Último acesso em: 20/11/2008.

M. JUNIOR, P. P. de. **Exames Virtuais Utilizando um Algoritmo de Ray Casting Acelerado**. 1999. 75p. Mestrado em Ciências em Informática — Departamento de Informática, PUC-Rio, Rio de Janeiro.

MCINERNEY, T.; TERZOPOULOS, D. T-Snakes: topoloy adaptive snakes. **Medical Image Analysis**, [S.l.], v.4, p.73–91, 2000.

MILANI, C. R. **Ferramenta Multithread para Reconstrução Volumétrica de Imagens em Medicina Nuclear para Auxílio na Detecção de Zonas Epileptogênicas**. 2007.

MILSZTAJN, F. **Segmentação de tecidos cerebrais em imagens de ressonância magnética utilizando campos aleatórios de Markov**. 2003. 92p. Dissertação (Mestrado em Ciência da Computação) — Universidade Federal do Paraná, Pós-graduação em Informática, Setor de Ciências Exatas, Curitiba.

MITA. **Medical Imaging and Technology Alliance**. Endereço eletrônico: <http://www.medicalimaging.org/> Último acesso em: 20/11/2008.

MOREIRA, D. F. **Jogo patológico: análise por neuroimagem, neuropsicológica e de personalidade**. 2004. 143p. Tese (Doutorado em Ciência da Computação) — Faculdade de Medicina, Universidade de São Paulo, São Paulo.

MORTENSEN, E. N.; BARRET, W. A. Interactive Segmentation with Intelligent Scissors. **Graphical Models and Image Processing**, [S.l.], v.60, n.5, p.349–384, 1998.

MORTENSEN, E. N.; REESE, L. J.; BARRET, W. A. Intelligent Selection Tools. In: IEEE SYMPOSIUM ON INFORMATION VISUALIZATION 98, 2000. **Anais...** IEEE Conference on Computer Vision and Pattern Recognition (CVPR 99), 2000. v.2, p.776–777.

NEMA. **The Association of Electrical and Medical Imaging Equipment Manufacturers**. Endereço eletrônico: <http://www.nema.org/> Último acesso em: 20/11/2008.

NUNES, E. O.; CONCI, A. Segmentação por Textura e Localização do Contorno de Regiões em Imagens Multibandas. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR 99), 2007. **Anais...** IEEE Latin America Transactions, 2007. n.3, p.185–192. (1, v.5).

OLIVEIRA, L. F. de. **Fusão de Imagens 3D para Localização e Quantificação de Zona Epileptogênica**. 2005. 136p. Tese (Doutorado em Ciência da Computação) — Faculdade de Medicina de Ribeirão Preto da Universidade de São Paulo, Ribeira Preto.

OLIVEIRA, M. C. **Visualização de Volumes em Morfometria de Estruturas Cerebrais a partir de Imagens de Ressonância Magnética Nuclear**. 2002. 78p. Dissertação (Mestrado em Ciência da Computação) — Faculdade de Filosofia, Ciências e Letras da Universidade de São Paulo, São Paulo.

PERONA, P.; MALIK, J. Scale-Space and Edge Detection Using Anisotropic Diffusion. In: IEEE LATIN AMERICA TRANSACTIONS, 1990. **Anais...** IEEE Transactions on Pattern Analysis and Machine Intelligence, 1990. v.12, n.7.

PRATT, W. K. **Digital Image Processing: PIKS Scientific Inside**. 4.ed. Hoboken, New Jersey: Wiley-Interscience, 2007.

RASBAND, W. **ImageJ: image processing and analysis in java**. Endereço eletrônico: <http://rsbweb.nih.gov/ij/> Último acesso em: 22/11/2008.

RUSS, J. C. **The Image Processing Handbook**. 5.ed. Boca Raton, FL 33487-2742: CRC Press, 2007. 817p.

SABINS, F. F. **Remote Sensing: Principles and Interpretation**. 2.ed. New York: W. H. Freeman, 1987.

SANTOS, V. T. **Segmentação de Imagens Mamográficas para Detecção de Nódulos em Mamas Densas**. 2002. Dissertação (Mestrado em Ciência da Computação) — Universidade De São Paulo, Escola de Engenharia de São Carlos, São Carlos.

SEIXAS, F. L.; SOUZA, A. S. de; SANTOS, A. A. S. M. D. dos; SAADE, D. C. M. Automated Segmentation of the Corpus Callosum Midsagittal Surface Area. In: IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE, 2007, Belo Horizonte, Minas Gerais, Brasil. **Anais...** The 20th Brazilian Symposium on Computer Graphics and Image Processing: SIBGRAPI 2007, 2007.

YOO, T. S. **Insight into Images: Principles and Practice for Segmentation, Registration, and Image Analysis**. Wellesey: AK Peters, Ltd., 2004. 399p.

YUAN, B.; GALLAGHER, M.; CROZIER, S. MRI Magnet Design: search space analysis, EDAs and a real-world problem with significant dependencies. In: THE 20TH BRAZILIAN SYMPOSIUM ON COMPUTER GRAPHICS AND IMAGE PROCESSING, SIBGRAPI 2007, 2005, New York. **Anais...** The Genetic and Evolutionary Computation Conference: GECCO-2005 - ACM Press, 2005. v.2, p.2141–2148.

ZANCHET, B. A. **Desenvolvimento de uma Ferramenta para Análise Quantitativa de Espessamento do Miocárdio através do Processamento de Imagens Médicas Digitais**. 2007. 62p.