Maryana de Carvalho Alegro

**Segmentação de Tumores do Encéfalo em Imagens
por Ressonância Magnética Baseada em Informações
Texturais**

Dissertação apresentada à Escola Politécnica da
Universidade de São Paulo para a obtenção do
título de Mestre em Engenharia Elétrica

São Paulo
2009

Maryana de Carvalho Alegro

**Segmentação de Tumores de Encéfalo em Imagens
por Ressonância Magnética Baseada em Informações
Texturais**

Dissertação apresentada à Escola Politécnica da
Universidade de São Paulo para a obtenção do
título de Mestre em Engenharia Elétrica

Área de Concentração: Sistemas Eletrônicos

Orientadora: Profa. Dra. Roseli de Deus Lopes

São Paulo

2009

Este exemplar foi revisado e alterado em relação à versão original, sob responsabilidade única do autor e com anuência de seu orientador.

São Paulo, 20 de Maio de 2009

Assinatura do autor

Assinatura do orientador

FICHA CATALOGRÁFICA

Alegro, Maryana de Carvalho

Segmentação de tumores do encéfalo em imagens por ressonância magnética baseada em informações texturais / M.C.

Alegro. Ed. Rev. -- São Paulo, 2009.

p.

Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Sistemas Eletrônicos.

1. Processamento digital de imagens 2. Imagem por ressonância magnética 3. Textura (Avaliação) 4. Neoplasias do sistema nervoso I. Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Sistemas Eletrônicos II. t.

*"Dominar-se a si próprio é uma vitória maior do que
vencer a milhares em uma batalha"*

- Sakyamuni -

Agradecimentos

Agradeço principalmente à minha orientadora, Profa. Dra. Roseli de Deus Lopes, por sua dedicação para com a minha formação acadêmica, profissional e moral, sendo para mim um exemplo a ser seguido.

Agradeço aos meus pais, Mary e Ricardo, por toda educação que me deram, pelo amparo em meus estudos e principalmente pelo exemplo de vida; e também à minha avó Maria Piedade e à minha tia Maria do Socorro por todo o carinho, incentivo e força.

Agradeço ao João Oda, por toda sua paciência e suporte durante esses últimos meses. E aos amigos Ricardo Herrmann, Michelle Massatelli, e Camila Suifi por sua companhia e milhares de conversas interessantes ao longo de todos esses anos.

Gostaria de agradecer aos médicos Dra. Rita de Cássia Maciel Pincerato, Dr. Edson Amaro Jr., e Dra. Claudia da Costa Leite, do Hospital das Clínicas da Universidade de São Paulo, por suas colaborações nesse trabalho, fornecendo os exames e segmentações manuais utilizados; ao Dr. Vicente Odone Filho, do Instituto da Criança, por seus comentários e ajuda, que possibilitaram o início desse trabalho, e a todos os amigos e colegas do LSI e da Escola Politécnica, com quem eu sempre pude contar como colaboradores, em todos os momentos do desenvolvimento deste trabalho.

Resumo

As imagens por ressonância magnética são indispensáveis no diagnóstico e tratamento de tumores do encéfalo devido ao seu alto grau de detalhamento anatômico. A tarefa de segmentação da região tumoral, nestas, permite uma análise quantitativa mais precisa, viabilizando um melhor acompanhamento da evolução/regressão da doença. Porém, a realização manual de tal trabalho é cansativa e apresenta diversas desvantagens que a tornam proibitiva, fazendo com que não haja muitos médicos dispostos a realizá-la rotineiramente.

Neste trabalho é proposto um sistema para segmentação automática de tumores do encéfalo. O sistema emprega parâmetros de textura de naturezas diversas, como estatísticos, baseados em modelo, e baseados em transformada, os quais são extraídos de diferentes tipos de imagem comuns à prática médica (T1, T1 com contraste e FLAIR). As técnicas de análise de textura são capazes de detectar alterações mínimas nos tecidos, às vezes imperceptíveis à visão humana, fato que motiva sua adoção; e podem ser complementadas por informações adicionais como valores de intensidade. O sistema proposto conta com quatro etapas básicas: pré-processamento, extração de características, segmentação e pós-processamento; e baseia-se no uso de uma máquina de vetor de suporte para classificação dos pixels.

Os resultados obtidos mostram que o sistema apresenta uma taxa média de acerto elevada, comparável aos resultados encontrados em trabalhos relacionados, sendo capaz de localizar e delimitar a região tumoral sem necessidade de interação com o usuário. A quantificação dos resultados foi realizada utilizando-se métricas de artigos encontrados na literatura.

Palavras-chave: processamento digital de imagens, imagem por ressonância magnética, textura (avaliação), neoplasias do sistema nervoso

Abstract

Magnetic resonance images are essential in the diagnosing and treatment of brain tumors due to its high amount of anatomic details. The task of segmenting brain tumor regions in these images makes more exact quantitative analysis feasible, allowing a better tracking of the evolution/regression of the disease. Nevertheless, the execution of such task is burdensome, featuring several drawbacks that turns it into a prohibitive one, and makes many doctors unwilling to put it into practice.

In this work an automatic brain tumor segmentation system is proposed, in which several types of texture parameters such as statistical, model based and transform based, are applied. Those parameters are extracted from different, extensively used, types of magnetic resonance images (T1, T1 with contrast and FLAIR). Texture analysis techniques are capable of detecting tiny changes in underlying tissue, which are sometimes imperceptible to the human vision, fact that motivates its adoption here. Texture features can also be completed by other kinds of characteristics, such as pixel intensity. The proposed system comprises four basic steps: pre-processing, feature extraction, segmentation, and post-processing, and is based on a support vector machine for pixel classification.

Final results shows that the system archived high success rates, which are comparable to results found in related works, and that it was able to locate and delimit tumor areas without any user interaction. For the quantification of the results, some metrics found in papers presented in the literature were adopted.

Key-words: digital image processing, magnetic resonance image, texture (evaluation), neoplasm of the nervous system

Lista de Figuras

2.1	Movimento de precessão	24
2.2	Magnetização longitudinal	24
2.3	Magnetização transversal	25
2.4	FID, T2* e o movimento de precessão em torno de Z (HORNAK, 1996) . .	26
2.5	Relaxação T1	28
2.6	Relaxação T2	29
2.7	Seqüência spin-echo	30
2.8	Retroprojeção: rotação do gradiente (HORNAK, 1996)	32
2.9	Retroprojeção: processamento dos sinais (HORNAK, 1996)	32
2.10	Retroprojeção: imagem resultante (HORNAK, 1996)	33
2.11	T2 e T1 com 5% e 9% de ruído, respectivamente, obtidas pelo simulador (BRAINWEB, 1997)	34
2.12	T2 e T1 com 20% e 40% de heterogeneidade respectivamente, obtidas pelo simulador (BRAINWEB, 1997)	35
2.13	Imagens adjacentes apresentando variação inter-fatias	36
2.14	Exemplo de imagens com intensidades despadronizadas	36
2.15	Texturas apresentadas em (JULESZ, 1962)	50
2.16	Vizinhanças de 1 ^a , 2 ^a , 3 ^a , 4 ^a , e 5 ^a ordem, para o ponto s	58
2.17	Cliques de uma vizinhança de segunda-ordem (TUCERYAN; JAIN, 1998) .	58
2.18	Algoritmo PTPSA (IFTEKHARUDDIN; ZHENG; ISLAM, 2006)	60
2.19	Passos básicos para extração de características	60

2.20	Canais de uma imagem filtrada por wavelets, e exemplo de uma imagem filtrada por uma db4 (família Daubechies)	63
3.1	Etapas e respectivos processos do sistema	66
3.2	Exemplo de histogramas com pixels de fundo. À esquerda: histograma bimodal, à direita: histograma unimodal	70
3.3	Histogramas bimodal e unimodal, sem pixels de fundo (NYUL; UDUPA, 1999).	70
3.4	Separador linear e suas margens	75
3.5	Problema linearmente separável e seu classificador, obtido por uma SVM	76
3.6	Problema com fronteiras suaves e classificador, obtido por uma SVM	77
3.7	Problema não linearmente separável e classificador	78
4.1	Máscaras utilizadas no pré-processamento	81
4.2	Resultado das sub-etapas do pré-processamento	82
4.3	Resultado do cálculo de características de MCO de um conjunto de imagens (T1, T1c e FLAIR)	82
4.4	Resultado do cálculo de características de textura estatísticas, baseadas em modelo e em transformada, de um conjunto de imagens (T1, T1c e FLAIR)	83
4.5	Resultado final da etapa de segmentação	85
4.6	Resultado final após a etapa de pós-processamento	86
5.1	Resultados do processamento da tupla #1 do paciente #1	97
5.2	Resultados do processamento da tupla #1 do paciente #5	98
5.3	Resultados do processamento da tupla #2 do paciente #7	99
5.4	Resultados do processamento da tupla #2 do paciente #11	100
5.5	Resultados do processamento da fatia #3 do paciente #11	101

Lista de Tabelas

5.1	Quantidade de positivos verdadeiros (PV), falsos positivos (FP), e falsos negativos (FN) em relação ao padrão ouro dos dois radiologistas e respectivas médias	93
5.2	Proporção entre PVs, FPs, FNs e o padrão ouro	94
5.3	PAs e TCs obtidas comparando-se o padrão ouro dos dois radiologistas, e PAs e TCs médias	95
5.4	Resultados apresentados em (ZHANG; MA; ER, 2004) (modificado)	96
5.5	Resultados apresentados em (ZHOU et al., 2005) (modificado)	96
A.1	Informações adicionais sobre os exames utilizados no trabalho	105
A.2	Informações técnicas dos exames utilizados no trabalho	106

Lista de Acrônimos

DP densidade de prótons

DTI *diffusion tensor imaging* - imagem de tensor de difusão

FDP função densidade probabilidade

FID *free induction decay* - decaimento de indução livre

FN falsos negativos

FP falsos positivos

GBM glioblastoma multiforme

líquor líquido encéfalo-raquidiano

MCO matriz de co-ocorrência

RF rádio-frequência

RM ressonância magnética

SB substância branca

SC substância cinzenta

SNC sistema nervoso central

SVM *support vector machine* - máquina de vetor de suporte

TE *time to echo* - tempo de eco

TI *time to invert* - tempo de inversão

TR *time to repeat* - tempo de repetição

T1c imagem ponderada em T1 com contraste

PA porcentagem de acerto

PV positivos verdadeiros

PO padrão ouro

TC taxa de correspondência

Sumário

1	Introdução	16
1.1	Objetivo	19
1.2	Motivação	19
1.3	Materiais e Métodos	20
1.4	Trabalhos Correlatos	20
1.5	Estrutura do Texto	21
2	Principais Conceitos para Segmentação de Tumores do Encéfalo	22
2.1	Introdução às Técnicas de Ressonância Magnética	22
2.1.1	Princípios da Ressonância Magnética Nuclear	23
2.1.2	Seqüências de Pulso	29
2.1.3	Gradientes e Reconstrução de Imagens	30
2.2	Artefatos em Imagens Geradas por Ressonância Magnética	33
2.2.1	Ruído	33
2.2.2	Efeito de Volume Parcial	34
2.2.3	Heterogeneidade de Intensidade	35
2.2.4	Falta de Padronização de Intensidade	36
2.3	Segmentação de Imagens	37
2.3.1	Detecção de Descontinuidades	38
2.3.2	Limiarização	39
2.3.3	Orientação por Regiões	40

2.4	Reconhecimento de Padrões na Segmentação Automática de Tumores do Encéfalo	40
2.4.1	Aprendizado Supervisionado	43
2.4.2	Aprendizado Não-Supervisionado	44
2.4.3	Seleção de Características	45
2.5	Análise de Texturas	46
2.5.1	Métodos Estatísticos	51
2.5.2	Métodos Estruturais	56
2.5.3	Métodos Baseados em Modelo	57
2.5.4	Métodos Baseados em Processamento de Sinais	60
2.6	Conclusão	64
3	Proposta de um Sistema para Segmentação de Tumores do Encéfalo	65
3.1	Etapas do Sistema	66
3.2	Pré-processamento	66
3.2.1	Correção de Heterogeneidade	67
3.2.2	Suavização de Ruído	67
3.2.3	Registro	68
3.2.4	Remoção do Tecido Extra-encefálico e Fundo	69
3.2.5	Padronização de Intensidade	71
3.3	Extração de Características	72
3.3.1	Extração de textura	72
3.3.2	Seleção de Características	72
3.4	Segmentação	73
3.4.1	Classificação	73
3.4.2	Máquinas de Vetor de Suporte	74
3.5	Pós-processamento	79

3.6	Conclusão	79
4	Implementação do Sistema para Segmentação de Tumores do Encéfalo	80
4.1	Pré-processamento	80
4.2	Extração de Características	82
4.2.1	Seleção de Características	84
4.3	Segmentação	85
4.4	Pós-processamento	86
4.5	Conclusão	87
5	Resultados Obtidos	88
5.1	Comparação com Resultados da Literatura	88
5.2	Conclusão	92
6	Conclusão	102
6.1	Considerações Finais	102
6.2	Contribuições	103
6.3	Trabalhos Futuros	103
	Apêndice A – Informações sobre os Exames Utilizados	105
	Apêndice B – Artefatos em Imagens de por Ressonância Magnética	107
	Referências Bibliográficas	109

1 Introdução

Tumores, ou neoplasias, são doenças causadas pelo crescimento desordenado de células do organismo. São originados por mutações no DNA que afetam o metabolismo celular, e podem ocorrer em praticamente qualquer parte do corpo, como pele, ossos e órgãos internos. Há muitos fatores causadores de tumores (como radiação, vírus e poluentes) e muitos tipos de tumor, desde os benignos, facilmente tratáveis e com cura total, aos malignos, de difícil tratamento e com sobrevida de meses. Os tumores do sistema nervoso central (SNC) constituem um grupo que merece atenção pois, apesar de apresentarem menor frequência de casos, representam um grupo de doenças severas uma vez que os danos infligidos por estes aos pacientes podem trazer sequelas bastante graves. No caso dos tumores do encéfalo, tanto tumores malignos quanto os dito benignos, são comumente fatais devido às características infiltrativas dos primeiros, e tendência de malignização dos últimos (BEHIN et al., 2003). A oncogênese das neoplasias de encéfalo é atribuída a uma variedade de fatores de risco como dieta, tabagismo, álcool, radiação, infecções, alergias, traumas cranianos e heranças genéticas. Porém, não há provas suficientes para corroborar tal afirmação (ALI-OSMAN, 2005).

O SNC é composto pelo encéfalo (que engloba principalmente o cérebro e cerebelo) e medula espinhal, os quais são envoltos pelas meninges e ossos do crânio e coluna vertebral. Sua função é coordenar os sistemas biológicos que compõem o corpo e é fundamental no controle do comportamento humano. Estima-se que 189 mil casos de câncer do SNC sejam diagnosticados por ano no mundo, dentro dos quais há mortalidade de 142 mil. Tais valores representam respectivamente 1,7% das novas ocorrências de câncer e 2,1% das mortes por este, mundialmente (PARKIN et al., 2001, 2005). No Brasil, no período entre 2002 e 2004, a taxa de mortalidade devido a tumores do SNC foi de 3,02 para cada 100.000 mulheres e de 3,44 para cada 100.000 homens. Neste mesmo período, ocorreu uma média de 13.137 internações anuais para o tratamento destes, sendo esses dados referentes apenas à rede pública de saúde (BOING; VARGAS; BOING, 2007). Os tumores do SNC representam 20% dos tumores infantis, ocorrem geralmente antes dos 15 anos e

acometem predominantemente crianças do sexo masculino (INCA, 2007). Especificamente para câncer do encéfalo, a taxa de mortalidade bruta, no Brasil, foi de 1,85 para cada 100.000 homens e 1,49 para cada 100.000 mulheres, no período entre 1995 e 1999 (INCA, 1999).

As neoplasias do SNC de maior ocorrência são as cerebrais, sendo gliomas e linfomas os tumores cerebrais primários mais comuns em adultos. Estudos estatísticos apontam que 90% de todas as ocorrências de tumores cerebrais diagnosticadas são gliomas malignos (normalmente fatais), sendo 70% destes glioblastomas multiformes (GBM); cujas características mais marcantes são a alta capacidade de infiltração nos tecidos adjacentes, rápida progressão e alta taxa de reincidência, levando o paciente à morte em poucos meses. As estatísticas indicam que o tempo médio para reincidência do GBM é de 6 meses e a sobrevida média do paciente 10 meses (GALANIS et al., 1998). Existem diversos outros tipos de tumores cerebrais, benignos e malignos, primários ou de origem metástica. Porém, o GBM recebe considerável atenção da comunidade médica devido à sua agressividade e alta taxa de incidência.

O tratamento padrão recomendado para tumores do encéfalo é a ressecção cirúrgica, aliada à quimioterapia e radioterapia (para os casos de câncer). Porém, boa parte dos tumores malignos do encéfalo apresentam resistência aos agentes quimioterápicos, sendo seus efeitos muito reduzidos (quando não nulos). Já o uso de radioterapia apresenta apenas pequenas melhoras no estado geral dos pacientes, trazendo redução temporária dos sintomas (BEHIN et al., 2003; ALI-OSMAN, 2005). O grau de dificuldade da intervenção cirúrgica varia dependendo das condições do paciente e do tipo do tumor. A cirurgia de tumores benignos não infiltrativos, como os meningiomas, tende a ser mais simples e com grandes chances de cura total após ressecção completa. Já tumores de natureza infiltrativa tendem a confundir os cirurgiões, pois é impossível delinear suas bordas com exatidão através de inspeção visual, podendo ser impossível sua ressecção total sem danos maiores ao paciente. Em alguns casos, a realização de cirurgias é inviável, uma vez que o tumor está localizado em regiões responsáveis por funções vitais do organismo. Este é o caso do astrocitoma de tronco difuso, que se desenvolve no tronco cerebral, onde uma cirurgia é fatal para o paciente, restando aos médicos apenas a opção de acompanhar o desenvolvimento da doença através de exames por imagem realizados periodicamente, e realizar quimioterapia e radioterapia.

As atividades que envolvem o diagnóstico inicial dos tumores do encéfalo, acompanhamento de seu desenvolvimento, resposta aos tratamentos, e planejamento cirúrgico,

são todas dependentes de exames radiológicos; principalmente devido à organização estrutural do SNC, cujos órgãos são delicados e envolvidos por ossos. As modalidades de exames mais comumente aplicadas para estes casos são a tomografia computadorizada e a ressonância magnética. A tomografia computadorizada prevaleceu por muitos anos como modalidade de exame chave para inspeção detalhada do SNC, uma vez que era capaz de produzir imagens dos órgãos internos com uma qualidade que, até sua invenção na década de sessenta, não era obtida por métodos de raio-x convencionais, sem ser invasiva ou destrutiva para o paciente (RANGAYYAN, 2005). Dentre as vantagens da tomografia computadorizada estava a produção de imagens do corpo em fatias, onde apenas a região de interesse era irradiada evitando que o paciente recebesse doses excessivas de radiação (como ocorria nos métodos de raio-x convencionais). Mais recentemente, a tomografia computadorizada teve parte de seu lugar ocupado pelos aparelhos de imagem por ressonância magnética (RM) que se tornou a tecnologia padrão no diagnóstico de tumores do SNC e, conseqüentemente, dos tumores do encéfalo. Algumas das vantagens que a RM traz sobre sua predecessora são:

- maior resolução e contraste;
- maior flexibilidade na escolha dos parâmetros de aquisição das imagens;
- possibilidade de obtenção de secções em diferentes posições (em contrapartida à tomografia que só possibilitava a obtenção de secções transversais);
- uso de radiação não-ionizante, que não possui efeitos nocivos conhecidos.

Tanto a ressonância magnética quanto a tomografia computadorizada fornecem alto nível de detalhamento estrutural dos órgãos. Sendo a ressonância capaz de registrar detalhes muito menores, como pequenos tumores ainda em formação, que passariam despercebidos nas imagens de tomografia (MOORE; NEWELL; LUMLEY, 2004).

Apesar do alto grau de detalhamento anatômico fornecido pelas imagens de ressonância magnética, a precisão na delimitação das bordas dos tumores encefálicos ainda é limitada por fatores humanos como grau de experiência do médico, fadiga, distração, etc; e da própria imagem, que pode ser de baixa qualidade, com contraste ruim, e ter presença de borrões e artefatos (RANGAYYAN, 2005). A atividade de delimitar, ou segmentar, as bordas da massa tumoral é normalmente realizada visualmente, com a segmentação manual do tumor, a qual apresenta três grandes problemas: a) baixa sensibilidade, detectando apenas mudanças grandes (SCHMIDT, 2005); b) grande variação do resultado

obtido entre diferentes médicos; c) necessidade de grande quantidade de tempo para realização de segmentação detalhada. Experiências com sistemas computacionais mostram que ferramentas de apoio a essa atividade podem trazer benefícios reais à prática médica (CLARKE; et al., 1998; VAIDYANATHAN, 1997), através de seu uso para segmentar automaticamente o tumor e calcular seu volume com mais exatidão.

1.1 Objetivo

O objetivo deste trabalho é a concepção, implementação e avaliação preliminar de um sistema baseado no uso de características texturais para segmentação de massas tumorais em imagens de ressonância magnética do encéfalo, com ênfase nos tumores cerebrais, que seja capaz de diferenciar entre dois tipos de tecido: tumor e não-tumor. Este sistema não deve se limitar ao processamento de imagens de um tipo determinado de tumor, sendo capaz de lidar com tipos diversos.

1.2 Motivação

A segmentação de regiões tumorais em imagens por ressonância magnética poderá permitir a delimitação da área de interesse de forma mais rápida e automática, não incorrendo nas desvantagens anteriormente citadas, e seus resultados poderão ser aplicados em atividades como planejamento pré-cirúrgico, criação de renderizações volumétricas, e principalmente quantificação de mudanças ocorridas na massa tumoral durante um certo período de tempo. A segmentação é uma tarefa importante no acompanhamento do desenvolvimento/regressão da doença e verificação da eficiência do tratamento empregado.

A utilização de sistemas computadorizados para segmentação de imagens radiológicas de tumores encefálicos não visa substituir o médico, mas sim auxiliar em seu trabalho por meio da execução de tarefas repetitivas de forma automática, deixando-o livre para exercer plenamente sua função intelectual. Os sistemas computadorizados não estão sujeitos à fadiga ou distrações, sendo capazes de detectar detalhes que poderiam passar despercebidos pelo olho humano.

A presença de células tumorais altera os tempos de relaxação da ressonância magnética, alterando o sinal captado e causando diferenças texturais visualmente imperceptíveis entre tecidos normais e doentes (GARCÍA; MORENO, 2004; ZHANG; MA; ER, 2004); porém, que podem ser captadas através da utilização de métodos matemáticos apropri-

ados (SANTOS et al., 2004). Tal fato indica que as informações de textura apresentam bom potencial como ferramenta na distinção entre tecidos saudáveis e tumorais.

1.3 Materiais e Métodos

Para atingir o objetivo aqui estabelecido, um método para segmentação de tecidos tumorais é proposto com base em estudos realizados sobre o estado-da-arte na área. Tais estudos levaram em conta artigos recentemente publicados, livros sobre o assunto e informações obtidas por meio de entrevistas e discussões com profissionais da área. Para testar o método proposto foram utilizados exames de RM reais obtidos junto aos médicos, cuja presença de tumores foi confirmada através de biópsia. Para realização deste trabalho utilizou-se a infra-estrutura da biblioteca da Escola Politécnica para pesquisas, um *desktop* ligado à internet para pesquisa e implementação, e infra-estrutura do equipamento de RM, de responsabilidade do Hospital das Clínicas, para realização dos exames.

A escolha dos algoritmos utilizados na implementação foi feita com base nos dados colhidos durante a fase de pesquisa, e o resultado prático foi obtido através de implementação e testes, resultando em um protótipo que conta com todas as funcionalidades propostas. A fase seguinte à implementação foi a de avaliação dos resultados obtidos. Nessa fase houve maior necessidade de contato com médicos da área, como radiologistas e oncologistas. Tal avaliação foi realizada através da comparação entre imagens segmentadas pelo sistema e manualmente por médicos colaboradores. A quantificação do sucesso dos resultados foi realizada através da comparação com artigos existentes na literatura, que explicam com clareza a métrica utilizada (FLETCHER-HEATH et al., 2001; ZHANG; MA; ER, 2004; ZHOU et al., 2005). As mesmas métricas foram implementadas e aplicadas de forma a permitir uma comparação.

1.4 Trabalhos Correlatos

Este trabalho se insere na linha de pesquisa em telemedicina do núcleo de Saúde Digital, do Laboratório de Sistemas Integráveis (LSI). O trabalho pioneiro no processamento de imagens do SNC desenvolvido foi realizado pelo então aluno de mestrado Fábio José Ayres, dos Meios Eletrônicos Interativos do LSI, cuja dissertação “Segmentação e Estimativa da Composição Histológica da Massa Tumoral em Imagens de CT de Neuroblastomas” (AYRES, 2001) tinha o objetivo de extrair informações sobre a composição histológica da

massa tumoral de neuroblastomas, a partir imagens de exames por tomografia computadorizada. Nele foi proposto um algoritmo semi-automático de segmentação de tumores e um método estatístico para estimação da composição histológica a partir da região segmentada. O trabalho aqui descrito pode ser visto como um complemento do trabalho sobre neuroblastomas, dentro da linha de processamento de imagens do SNC, pois seu foco está em tumores do encéfalo, enquanto no trabalho anterior o foco está em um tipo de tumor essencialmente extra-craniano; e porque trabalha com imagens de ressonância magnética, abordando sua teoria, vantagens e desvantagens.

1.5 Estrutura do Texto

O primeiro capítulo traz uma introdução ao problema dos tumores do encéfalo, mostrando um contexto global onde são fornecidas ao leitor algumas estatísticas sobre a ocorrência dessa doença, as possíveis abordagens para seu tratamento, e dificuldades encontradas pelos médicos para análise dos exames de RM, juntamente com o objetivo deste trabalho e a estratégia para realizá-lo.

No segundo capítulo, apresentam-se os principais conceitos e métodos necessários para a compreensão deste trabalho, sem a pretensão de esgotar os assuntos. Entre os temas abordados estão a base da teoria de RM, principais características e técnicas para processar essas imagens, tópicos de reconhecimento de padrões úteis a este trabalho, e uma revisão sobre as principais técnicas de análise de texturas.

No terceiro capítulo, a proposta concebida para a segmentação de tumores do encéfalo é apresentada de forma detalhada, justificando-se os motivos e vantagens das abordagens adotadas.

O quarto capítulo apresenta os detalhes e sutilezas da implementação do protótipo do sistema proposto.

No quinto capítulo são apresentados os resultados obtidos, e realiza-se uma comparação com artigos relevantes da área.

No sexto capítulo há uma breve discussão sobre o trabalho, juntamente com as principais conclusões, contribuições geradas e sugestões de possíveis trabalhos futuros.

2 Principais Conceitos para Segmentação de Tumores do Encéfalo

A área de processamento de imagens médicas abrange um amplo espectro de aplicações que vai desde a geração de imagens computadorizadas até o uso de sofisticados métodos de análise e detecção de patologias, passando por atividades como realce e correção de ruído, reamostragem, remoção de artefatos, compactação para arquivamento, entre outros. O advento da ressonância magnética possibilitou a obtenção de imagens mais detalhadas dos órgãos internos do corpo de forma não invasiva, facilitando uma maior compreensão das estruturas de órgãos, como o cérebro, e mudando completamente o cenário da análise de imagens médicas (DUNKAN; AYACHE, 2000). Técnicas de processamento de imagens com fins de análise do tecido encefálico, vêm sendo estudadas há algum tempo, mostrando-se úteis no auxílio a diagnósticos. Neste capítulo, será feita uma breve visita aos princípios da ressonância magnética, seguida pela apresentação dos vários conceitos teóricos necessários para a realização do trabalho aqui proposto, sem a pretensão de esgotar o assunto, mas de expor ao leitor o que há de atual nos conceitos ligados ao tratamento e segmentação de imagens de tumores do encéfalo por RM.

2.1 Introdução às Técnicas de Ressonância Magnética

As técnicas de imageamento por ressonância magnética atuais baseiam-se no fenômeno da Ressonância Nuclear Magnética (RNM), descoberto na década de 40 independentemente por Felix Bloch e Edward Purcell. Tal fenômeno foi aplicado ao estudo físico e químico de moléculas durante as décadas de 50 a 70, e na década de 70 sua aplicação na medicina começou a ser estudada.

2.1.1 Princípios da Ressonância Magnética Nuclear

As partículas nucleares de um átomo (prótons e nêutrons, também chamados de nucleons) apresentam uma propriedade conhecida como *spin*, que lhes confere momento magnético não nulo, o que significa que estas possuem campo magnético próprio, apresentando comportamento de pequenos ímãs (mais formalmente conhecidos como dipolos magnéticos). Dentro de núcleos com número par de partículas os campos magnéticos desses dipolos são mutuamente anulados, gerando momentos magnéticos resultantes nulos. Porém, em núcleos com número ímpar de partículas o momento magnético nuclear resultante não é anulado, uma vez que sempre há uma partícula cujo campo magnético não foi neutralizado. Esse tipo de núcleo é suscetível à influência de campos magnéticos externos, sendo chamado de núcleo ativo. Alguns exemplos de elementos com núcleo ativo são o carbono 13, o hidrogênio, o flúor, e o sódio. Os equipamentos médicos de RM têm como alvo o hidrogênio por ser um elemento abundante na água e gordura, substâncias que compõem a maior parte do corpo humano (HORNAK, 1996; TOFTS, 2003). A capacidade desses elementos de serem influenciados por campos magnéticos externos ao corpo constitui a base das técnicas de ressonância magnética.

Quando elementos de núcleo ativo são submetidos a um campo magnético estático forte, o momento magnético de seus nucleons entra em movimento de precessão, e o resultado é um momento magnético resultante, do núcleo, alinhado ao campo magnético aplicado. Esse fenômeno é denominado acoplamento do núcleo na direção do campo. A figura 2.1 ilustra esse fenômeno, nela $\mathbf{M}$ é o momento magnético resultante dos movimentos de precessão dos nucleons (também conhecido como magnetização longitudinal), que está alinhado ao campo magnético $\mathbf{B}$. O alinhamento também pode ocorrer no sentido contrário ao campo, que resulta num estado de maior energia. A frequência do movimento de precessão é dada pela equação de Larmor:

$$\omega = \gamma B \quad (2.1)$$

Onde ω é a frequência angular, γ a constante giro-magnética ou constante de Larmor, e B a intensidade do campo magnético aplicado. É importante notar que a frequência de precessão é dependente da intensidade do campo B , pois é essa propriedade que vai permitir a obtenção de imagens pelas técnicas de codificação de fase e frequência discutidas adiante. Enquanto a resultante $\mathbf{M}$ está alinhada ao campo $\mathbf{B}$ não há nenhuma componente no plano XY e portanto nenhum sinal de RM pode ser medido, uma vez que a captação desses sinais é realizada por uma bobina posicionada paralelamente ao campo estático.

Figura 2.1: Movimento de precessão

Isso ocorre devido ao fato dos núcleos, nesse momento, se encontrarem precessionando aproximadamente na mesma frequência, porém fora de fase, o que faz com que os momentos magnéticos transversais se anulem. Entretanto, se um pulso de radiofrequência (RF) for aplicado perpendicularmente ao campo magnético, o movimento de precessão dos núcleos entrará temporariamente em fase, e então a resultante M começará a realizar precessão em volta do eixo do campo (no caso, eixo Z), como pode ser visto na figura 2.2 a. Caso esse pulso dure tempo suficiente, a componente iniciará o movimento de precessão em torno do eixo do pulso aplicado (no caso, X) e começará a se inclinar, como pode ser visto na figura 2.2 b. Essa inclinação gera as componentes M_0 no eixo Z e M_1 no plano XY (conhecido como magnetização transversal). Essa capacidade do núcleo de absorver a energia eletromagnética do pulso de RF e ser influenciado por ela é que dá origem a expressão *ressonância magnética*, pois o núcleo “ressoa” com o pulso.

Figura 2.2: Magnetização longitudinal

Para que um pulso de RF consiga afetar o núcleo de átomos de um determinado elemento, este deve estar na frequência de Larmor (ω), ou frequência de ressonância, do elemento em questão. Sendo assim, os equipamentos médicos de RM se concentram na frequência de precessão do hidrogênio (entre 15 e 80 MHz (HORNAK, 1996)). O movimento resultante da precessão em volta de Z e X tem a forma de uma espiral como ilustrado na 2.3 a. Caso o pulso seja configurado com o tempo certo, a resultante M sofrerá uma inclinação de 90° e realizará movimento de precessão em torno do eixo Z podendo então o sinal ser captado pela bobina (figura 2.3 b). O sinal captado pela bobina atinge seu máximo quando $M = M_1$. Porém, assim que surge a componente M_1 , algum sinal já é percebido. Tão logo o pulso de radiofrequência cessa, M_1 começa a decair e M_0 a se recuperar, uma

Figura 2.3: Magnetização transversal

vez que o sistema tende a perder energia para voltar a seu estado de equilíbrio inicial. Esse fenômeno é denominado relaxação. O sinal gerado pela precessão de M_1 em torno do eixo Z é conhecido como FID (*free induction decay* - decaimento de indução livre) e tem a forma mostrada na figura 2.4. A curva formada pelo envelope da senóide é conhecida como constante $T2^*$.

O tempo necessário para que M_0 se recupere é denominado relaxação $T1$, e o tempo que M_1 leva para decair no intervalo de repetição do pulso de RF é chamado relaxação $T2$. Mais especificamente, após o tempo de relaxação $T1$, em um campo de 1,5T, a componente longitudinal recuperou 63,2% do seu valor máximo; e após o tempo de relaxação $T2$ a componente transversal decaiu 37,2% do seu valor máximo, sendo que o tempo $T2$ é independente da intensidade do campo magnético e é normalmente mais curto que $T1$ (HORNAK, 1996; HOROWITZ, 1989).

Figura 2.4: FID, $T2^*$ e o movimento de precessão em torno de Z (HORNAK, 1996)

A relaxação das magnetizações ocorre devido a heterogeneidade do campo B , uma vez que é impossível obter na prática um campo perfeitamente homogêneo, e às interações entre os campos magnéticos dos nucleons (interações *spin-spin*). Aqui é importante notar que os tempos $T1$ e $T2$ do hidrogênio variam dependendo do tipo de ligação que está sendo realizado com outros elementos químicos, o que faz com que $T1$ e $T2$ do mesmo elemento sejam diferentes dependendo do tecido imageado. Os tempos de relaxação de tecidos normais estão relacionados à concentração de macromoléculas, presença de água e ligações com suas moléculas e podem ser alterados na presença de patologias; também podem variar dependendo da intensidade do campo estático aplicado. No cérebro, por exemplo, a mielina faz com que a substância branca tenha valor de relaxação $T1$ mais curto que o da substância cinzenta. Porém, a substância cinzenta possui tempo de relaxação $T2$ mais longo que a substância branca (TOFTS, 2003). São essas diferenças nos valores de relaxação as responsáveis pela obtenção de contraste nas imagens geradas por ressonância magnética. Os tempos de relaxação dos tecidos podem ser alterados pela presença de certas substâncias conhecidas como agentes de contrastes, que são utilizados para acentuar as diferenças nas imagens de tecidos durante a realização de um exame. Os tecidos que são mais afetados por sua presença são aqueles que possuam afinidade com a substância empregada, normalmente tecidos com maior vascularização. Na realização de exames do SNC é normal a utilização do gadolínio como agente de contraste. As imagens ponderadas em $T1$ são melhores para visualização da concentração de gordura, enquanto

as ponderadas em T2 são melhores na visualização da concentração de água (SCHMIDT, 2005).

Como foi dito anteriormente a aplicação de um pulso de RF permite a captação do sinal de ressonância, porém este rapidamente desaparece devido às heterogeneidades do campo estático e às interações *spin-spin*. Para que o sinal possa ser medido corretamente é então necessária a repetição do processo de emissão do pulso de RF e medição do sinal resultante. O tempo de repetição desse ciclo é chamado TR (*time to repeat*) e o tempo entre o início do ciclo e a leitura do sinal de TE (*time to echo*, tempo de eco, assim denominado pois os núcleos “ecoam” o sinal de RF emitido pelo equipamento).

As modalidades de imagens por ressonância magnética mais utilizadas em radiologia são as ponderadas em T1, ponderadas em T2 e as de densidade de prótons (DP). Imagens ponderadas em T1 são aquelas cujo contraste entre tecidos é obtido a partir das propriedades do tempo de relaxação T1, e as ponderadas em T2 a partir das propriedades do tempo de relaxação T2. A ponderação das imagens é obtida variando-se os tempos TR e TE. Por exemplo, para se obter imagens ponderadas em T1 deve-se escolher um TE curto, de forma a anular o efeito do tempo de relaxação T2, e um TR curto para reforçar o efeito do relaxação T1. Já para se obter uma imagem ponderada em T2, deve-se escolher TR longo para eliminar efeito de T1 e TE longo para reforçar o efeito de T2. As figuras 2.5 e 2.6 podem auxiliar na melhor compreensão sobre a configuração dos parâmetros TE e TR. Nelas são ilustrados os tempos de relaxação T1 (figura 2.5) e T2 (figura 2.6) de dois tecidos hipotéticos, A e B. Pode-se ver claramente na figura 2.5 que o tempo de relaxação T1 de A é menor que o de B pois a componente M_0 deste atinge seu valor original antes que a do tecido B. Agora, supondo que se emita um pulso de RF no tempo t_0 da figura, os vetores M do volume imageado seriam rotacionados e as componentes resultantes do tecido B seriam maiores que as do tecido A, o que causaria maior sinal proveniente de B. Porém, se o tempo esperado para realizar a emissão de pulsos de RF for maior (TR mais longo), por exemplo no tempo t_2 , praticamente não haveria distinção entre as componentes e conseqüentemente entre os sinais emitidos pelos tecidos. Tal fato evidencia que um tempo de repetição longo serve para anular o efeito no relaxação T1 no sinal gerado (HOROWITZ, 1989). Já na figura 2.6, pode-se ver que o tempo de relaxação T2 de A é menor que o de B, pois no momento em que a componente M_1 de A termina de decair, M_1 de B ainda encontra-se em processo de decaimento. Pelo gráfico pode-se notar também que se um tempo de leitura (TE) curto, for utilizado (por exemplo, leitura em t_0), nenhuma diferença entre M_1 de A e B será captado uma vez que não houve tempo destas decaírem o suficiente para se diferenciarem. Porém, se a leitura levar um tempo

Figura 2.5: Relaxação T1

maior pra ser realizada (por exemplo no tempo t_1 da figura) haverá bastante contraste entre as componentes M_1 dos tecidos. Isso evidencia que um tempo de leitura menor serve para anular os efeitos do relaxação T2 no sinal obtido (HOROWITZ, 1989). Sendo assim, para uma imagem ponderada em T1 deve-se escolher TE e TR curtos e para uma imagem ponderada em T2, TE e TR longos. Vale ressaltar que as imagens ponderadas em T2 usualmente são as que apresentam maior contraste entre tumor e tecido normal (TOFTS, 2003).

As imagens de densidade de prótons também são comumente utilizadas na radiologia, nelas adota-se preferencialmente um TE curto (entre 20ms e 30ms) e TR longo (2s à 5s) para eliminar o efeito dos tempos de relaxação T2 e T1, respectivamente. Essa modalidade de imagem privilegia a concentração de prótons livres (lembrando que o núcleo do hidrogênio contém apenas por um protom) nos tecidos; e em imagens do encéfalo, onde a densidade de prótons é aproximadamente a mesma da concentração de água dos tecidos, auxilia na visualização de edemas e inflamações causadas por patologias. Uma das aplicações das imagens de densidade de prótons no imageamento do tecido cerebral é a distinção entre este e tecido tumoral, pois foi empiricamente demonstrado que a concentração de prótons livres em tecido tumoral é maior que em tecido normal (TOFTS, 2003).

Figura 2.6: Relaxação T2

2.1.2 Seqüências de Pulso

Como foi dito anteriormente, as duas causas do decaimento rápido do sinal de ressonância são as interações *spin-spin* e as heterogeneidades do campo estático, que causam pequenas diferenciações na frequência de precessão dos núcleos e contribuem para a defasagem mais rápida do movimento. A primeira não pode ser corrigida por ser resultante de fenômenos internos dos núcleos, porém a segunda pode ser corrigida utilizando subterfúgios que lidem com a limitação de um campo estático imperfeito. A solução encontrada para corrigir tal problema foi a utilização de diferentes seqüências de pulsos, sendo a seqüência *spin-echo* a mais utilizada.

O *spin-echo* é formado por um pulso de RF inicial que causa a rotação de M em 90° seguido por um ou mais pulsos para rotação em 180° , cujo objetivo é reverter o processo de defasagem através da inversão de polaridade das componentes M_1 . Isso surte efeito pois, supondo que o tempo de defasagem de M_1 seja t , quando há aplicação do pulso de 180° estas componentes levam um tempo $2t$ para se defasarem novamente, o que significa que após um período de tempo t as componentes estarão em fase novamente e haverá uma breve revitalização do sinal gerado. Vale lembrar que é impossível restaurar perfeitamente o sinal e este sempre vai apresentar perdas mesmo após os pulsos de 180° , até que seja necessária a repetição do ciclo. A figura 2.7 ilustra os conceitos de TR, TE, T2, T2* e *spin-echo*.

Figura 2.7: Seqüência spin-echo

Uma seqüência de pulsos conhecida como *fast-scan* (chamada GRASS ou FLASH por alguns fabricantes de equipamentos) também é comumente utilizada para rápida obtenção de conjuntos de imagens em partes do corpo como abdômen e vasos sanguíneos. Nela são usados pulsos de RF de curta duração para obtenção de ângulos de giro menores que 90° , juntamente com tempos de repetição de duração reduzida; o que possibilita a rápida obtenção das imagens. A utilização de ângulos de giro maiores gera imagens próximas às ponderadas em T1 e o aumento de TE gera imagens próximas às ponderadas em T2.

Outro tipo de seqüência de pulsos bem conhecido, porém menos utilizado é chamado de recuperação de inversão (*inversion recovery*), que resulta em imagens ponderadas em T1. Nele pulsos de giro de 180° são aplicados ao vetor M , que inverte sua posição no eixo Z. Após um certo tempo de decaimento um pulso de giro de 90° é aplicado resultando então no vetor M_1 que pode ter seu sinal medido. Essa técnica permite a obtenção de maior contraste nas imagens ponderadas em T1 (COSTA et al., 2007). Aqui há a introdução de outro parâmetro de tempo, o tempo de inversão ou TI (Time to Invert).

2.1.3 Gradientes e Reconstrução de Imagens

A aquisição de imagens de ressonância magnética é intrinsecamente tridimensional, pois necessita de um sistema de três coordenadas para dar a localização de um pixel específico; sendo o eixo Z indicador da fatia a ser obtida e o plano XY uma imagem bidimensional da mesma, onde as coordenadas (x,y) identificam um pixel específico nesta (HOROWITZ, 1989). Para se obter essa tridimensionalidade os equipamentos de RM utilizam três gradientes no campo magnético: gradiente de seleção de fatia, gradiente de codificação de frequências e gradiente de codificação de fase. Tais gradientes são aplicados de forma a possibilitar a reconstrução da imagem captada. Através deles, os aparelhos

de ressonância magnética são capazes de selecionar as fatias desejadas e diferenciar os pixels no espaço, pois permitem que haja variação na frequência de precessão individual para cada núcleo, ou conjunto de núcleos, que irá formar um pixel da imagem, assim, permitindo distinção entre os mesmos. Sem o uso de gradientes todos os átomos de hidrogênio do volume imageado precessionariam na mesma frequência e só haveria um pico de RM no sinal captado, tornando impossível a distinção entre os pixels.

A seleção de fatias específicas é realizada com auxílio do gradiente seletor de fatias, G_z , que é aplicado na direção do eixo Z e causa uma pequena variação no campo magnético estático B , que faz com que as frequências dos movimentos de precessão individuais variem proporcionalmente à variação da intensidade do campo. Portanto, para selecionar uma fatia deve-se aplicar o pulso de RF numa frequência correspondente à frequência de Larmor daquela parte do corpo do paciente. A espessura da fatia pode ser configurada variando-se a frequência do pulso de RF dentro de um certo intervalo de frequências, ou variando-se o gradiente do campo magnético estático.

A distinção entre pixels no eixo X é realizada pelo gradiente de codificação de frequência, G_x , que é aplicado paralelamente ao eixo. Isso resulta em um campo magnético que tem intensidade diferente de um lado a outro do objeto imageado, fazendo com que existam colunas de núcleos com a mesma frequência de precessão, permitindo ao aparelho de ressonância magnética distinguir entre os pixels no eixo X.

A primeira técnica a utilizar codificação de frequência para gerar imagens foi a de retroprojeção. Nela, o volume a ser imageado é posicionado dentro de um campo magnético estático, que posteriormente tem um gradiente unidimensional aplicado em vários ângulos e para cada aplicação de gradiente o sinal resultante é registrado para posterior processamento. Na figura 2.8 um gradiente G é aplicado ao campo magnético estático. Para obter o sinal que será processado ele é rotacionado de 0° à 359° . Esse efeito é obtido aplicando-se uma combinação linear de dois gradientes, um na direção de X e outro na direção de Y. Depois que os sinais são medidos o algoritmo de retroprojeção é executado como ilustra a figura 2.9. Na figura 2.10 tem-se a imagem resultante após a remoção do sinal de fundo. O gradiente G também é conhecido como gradiente de frequência.

O terceiro gradiente utilizado, G_y , é denominado de gradiente de codificação de fase; é responsável por possibilitar a distinção entre pixels no eixo Y. Para tanto, não é possível utilizar o mesmo mecanismo do gradiente de frequência, pois os núcleos não precessionariam em frequências distintas, havendo dualidade e levando o equipamento a realizar uma reconstrução errada da imagem. A função do gradiente de codificação de fase é forçar as

Figura 2.8: Retroprojeção: rotação do gradiente (HORNAK, 1996)

Figura 2.9: Retroprojeção: processamento dos sinais (HORNAK, 1996)

fleiras de núcleos a sair de fase durante o movimento de precessão, o que resulta, após a aplicação do gradiente, nos núcleos dessas fleiras precessionando à mesma frequência, porém em fases distintas. Tal efeito, permite ao aparelho de ressonância magnética diferenciar os pixels. É importante ressaltar que o bom funcionamento dos gradientes depende da aplicação destes no momento certo, pois suas funções são determinadas principalmente pelo momento em que estes são aplicados. O gradiente de seleção de fatia (G_z) é aplicado enquanto o pulso de RF está ativo. Já o gradiente de codificação de frequência G_x só é aplicado no momento da leitura do sinal; e o gradiente de codificação de fase G_y no intervalo de tempo entre a suspensão do pulso de RF e o início da leitura do sinal.

O sinal medido pode ser representado por um espectro em um plano bidimensional (chamado na literatura de *k-space*), onde um dos eixos representa a variação de frequência e o outro a codificação de fase; a partir desse espectro os equipamentos de RM modernos

Figura 2.10: Retroprojeção: imagem resultante (HORNAK, 1996)

realizam a reconstrução da imagem utilizando a transformada de Fourier bidimensional:

$$\mathfrak{F}\{f(x,y)\} = F(u,v) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x,y) e^{-j2\pi(ux+vy)} dx dy \quad (2.2)$$

2.2 Artefatos em Imagens Geradas por Ressonância Magnética

Artefatos são quaisquer características apresentadas por uma imagem e que não estão presentes no objeto imageado. Podem ser ocasionados por mau funcionamento ou mau uso do equipamento, ou por processos naturais do corpo humano (HORNAK, 1996). É importante conhecê-los pois além comprometer a qualidade das imagens, podem causar interpretações errôneas por parte dos médicos e afetar o desempenho geral dos algoritmos empregados na segmentação de tecidos encefálicos, sejam eles normais ou tumorais (ANDRADE et al., 2002; SCHMIDT, 2005). O apêndice B apresenta os artefatos de imagem mais comuns em ressonância magnética, juntamente com uma breve descrição de suas causas. Este trabalho dará ênfase aos artefatos que causam maiores dificuldades na tarefa de segmentação, descritos detalhadamente a seguir.

2.2.1 Ruído

O ruído presente nas imagens por ressonância magnética pode ser causado por interferências oriundas de diversas fontes, como geradores de RF externos ao ambiente de aquisição (no caso da existência de blindagens de baixa qualidade ou defeituosas), oriundas do próprio equipamento, ou, na maioria dos casos oriundas de efeitos térmicos ocorridos

no corpo do paciente (HORNAK, 1996; NOWAK, 1999). Tal ruído é modelado pela distribuição de Rice, cuja função densidade probabilidade (FDP) é dada por:

$$f(x|v, \sigma) = \frac{x}{\sigma^2} e^{-(x^2+v^2)/2\sigma^2} I_0\left(\frac{xv}{\sigma^2}\right) \quad (2.3)$$

Onde I_0 é a função de Bessel modificada de primeiro tipo com ordem zero. Sendo que em regiões com maior sinal (mais claras) esse ruído tende a uma distribuição gaussiana e em regiões de baixo sinal (mais escuras) a uma distribuição de Rayleigh, cuja FDP é dada por:

$$f(x|\sigma) = \frac{x e^{-(x^2)/2\sigma^2}}{\sigma^2} \quad (2.4)$$

A presença de ruído nas imagens corrompe o sinal adquirido e dificulta a tarefa de

Figura 2.11: T2 e T1 com 5% e 9% de ruído, respectivamente, obtidas pelo simulador (BRAINWEB, 1997)

segmentação, devendo ser tratado na fase de pré-processamento. Na figura 2.11 tem-se duas imagens simuladas, ponderadas em T2 e T1 com 5% e 9% de ruído respectivamente. Pode-se notar, principalmente na imagem T1, a degradação dos detalhes devido à presença exagerada de ruído.

2.2.2 Efeito de Volume Parcial

O efeito de volume parcial existe quando a área de um pixel (ou volume de um voxel, no caso tridimensional) engloba mais de um tecido imageado. A intensidade nesse pixel é o resultado da combinação de sinais de tecidos adjacentes e não reflete o sinal verdadeiro presente naquela localidade, prejudicando o detalhamento anatômico da imagem e podendo acarretar diagnósticos errôneos.

2.2.3 Heterogeneidade de Intensidade

O artefato de não-uniformidade, ou heterogeneidade, de intensidade é caracterizado como uma variação de intensidade de baixa frequência, não relacionada a variações anatômicas, que ocorre ao longo de regiões homogêneas. Pode ser causado por diferentes fatores como não-uniformidade do campo estático do equipamento, não-uniformidade na radio-frequência, movimentos do paciente, correntes induzidas, entre outros. Sua presença pode

Figura 2.12: T2 e T1 com 20% e 40% de heterogeneidade respectivamente, obtidas pelo simulador (BRAINWEB, 1997)

causar cerca de 10%-20% de variação de intensidade, o que não causa impacto na avaliação visual das imagens, mas acarreta considerável queda de desempenho nos métodos de segmentação computadorizada.

A formação de uma imagem de RM ($i(\cdot)$) pode ser modelada como:

$$i(x) = u(x)e(x) + r(x) \quad (2.5)$$

Onde $u(\cdot)$ é o sinal real, $r(\cdot)$ o ruído, como já exposto anteriormente, e $e(\cdot)$ o campo multiplicativo de não-uniformidade. A estimação de $i(\cdot)$ é uma tarefa difícil devido à existência de diversos fatores, que somados originam o artefato, sendo alguns controláveis através da calibragem do equipamento, e outros variáveis dependentes do indivíduo a ser imageado. Portanto, o controle do campo de não-uniformidade durante a realização de uma aquisição é limitado, sendo necessária a aplicação de algoritmos de pré-processamento para que tal artefato seja reduzido (SLED; ZIJDENBOS, 1998). Na figura 2.12, principalmente na imagem ponderada em T1, pode-se notar a variação de intensidade causada pela presença de não-homogeneidade ao longo da imagem, sendo as extremidades mais escuras que a região central.

A variação de intensidade inter-fatias é um subtipo de heterogeneidade de intensidade,

que causa a variação geral de intensidades em fatias adjacentes de um mesmo volume (por exemplo, imagens ímpares podem se apresentar mais claras que imagens pares). Sua causa geralmente está ligada aos parâmetros empregados no protocolo de aquisição do exame. Na figura 2.13, tem-se imagens adjacentes de um mesmo volume real. Pode-se ver que a

Figura 2.13: Imagens adjacentes apresentando variação inter-fatias

segunda imagem apresenta tons de cinza discrepantes das outras.

2.2.4 Falta de Padronização de Intensidade

A existência de uma série de diferentes protocolos de aquisição leva a uma falta de padronização nos valores dos sinais adquiridos em um exame, o que faz com que haja diferenças na intensidade dos pixels entre exames adquiridos em diferentes equipamentos e/ou protocolos. Ou seja, ao contrário de modalidades de imageamento como tomografia computadorizada, onde os valores de atenuação dos tecidos são conhecidos e permitem fazer uma comparação direta com os valores obtidos nas imagens, na ressonância magnética os valores de intensidade não possuem um significado fixo a respeito do tecido imageado. Tal característica traz dificuldades principalmente para métodos de segmentação baseados em intensidade. Na figura 2.14, pode-se ver duas imagens referentes à mesma região do

Figura 2.14: Exemplo de imagens com intensidades despadronizadas

cérebro provenientes de volumes de exames de pacientes distintos. Nota-se que há uma

grande variação nos tons médios das imagens. Tal exemplo ilustra o efeito da falta de padronização de intensidade que há nos exames por ressonância magnética.

2.3 Segmentação de Imagens

A segmentação de imagens é responsável por dividir uma imagem em partes, objetos constituintes, ou regiões de interesse. Os algoritmos mais simples de segmentação baseiam-se em propriedades de descontinuidade e similaridade, onde, para imagens em tons de cinza como é o caso de RM, por descontinuidade entende-se a mudança abrupta de valores em escala de cinza dos pixels, e por similaridade entende-se a homogeneidade dos tons dos pixels (RANGAYYAN, 2005; GONZALEZ; WOODS, 2000). Devido à natureza complexa das imagens de ressonância magnética do encéfalo, dificilmente um sistema de segmentação de tumores se baseará unicamente neste tipo de processamento, necessitando agregar técnicas de reconhecimento de padrões e/ou aprendizado de máquina.

Em (GIBBS et al., 1996) imagens de RM ponderadas em T1c obtidas em diversos planos são segmentadas utilizando-se limiarização e filtragem espacial (filtro de Sobel, no caso) para detecção de bordas; e crescimento de regiões para geração da superfície segmentada. O pós-processamento é realizado por um filtro “vizinhos-mais-próximos” que é responsável por refinar a segmentação, retirando pixels que não estão ligados à região. Esse trabalho se concentra na segmentação de gliomas malignos e a intervenção do usuário é requerida para informar valores de intensidade médios para a região de tumor e as regiões adjacentes.

Já em (LETTEBOER et al., 2001) imagens de RM ponderadas em T1c contendo tipos variados de tumor são processadas, utilizando-se um algoritmo de *watershed* multi-escala de forma a segmentar os tumores. Nesse método, o usuário deve selecionar blocos de interesse em uma escala maior e ir refinando a segmentação através da inclusão ou exclusão de blocos em escalas menores.

O trabalho realizado em (ZHU; YAN, 1995) traz uma abordagem ainda baseada em operações simples, porém já fazendo uso de classificadores, no caso redes Hopfield, para agrupar os pixels da imagem. Nesse trabalho, limiarização e operações morfológicas são utilizadas para localizar regiões de interesse que alimentam um modelo de contornos ativos. As possíveis bordas localizadas pelo algoritmos de contorno ativo são classificadas por um rede neural.

2.3.1 Detecção de Descontinuidades

As formas mais triviais de segmentação de objetos em uma imagem são a detecção de pontos e linhas. Normalmente, são realizadas utilizando processamento local através do uso de uma máscara móvel de dimensão $N \times N$, onde o ponto central da máscara (R) recebe um valor calculado entre a máscara e a imagem sob esta, da forma:

$$R = \sum_{i=1}^N w_i \cdot z_i \quad (2.6)$$

sendo z_i o valor do pixel da imagem sob a posição w_i da máscara.

Diz-se que um ponto é identificado por uma máscara se:

$$|R| > T$$

sendo T um limiar pré-definido. A detecção de linhas pode ser realizada da mesma forma, variando-se os valores nas posições das máscaras, de forma que estas, quando aplicadas, causem respostas mais acentuadas de acordo com o ângulo dos coeficientes da máscara. Por exemplo, podem ser construídas máscaras para localização de linhas horizontais ou verticais.

Detecção de Bordas

Define-se uma borda como um limite entre duas regiões com propriedades relativamente distintas de níveis de cinza, onde há homogeneidade suficiente para que seja possível a distinção da transição entre estas, baseando-se apenas nas descontinuidades dos tons (GONZALEZ; WOODS, 2000). A detecção de bordas geralmente é realizada através de operadores diferenciais locais. De maneira geral, a magnitude da primeira derivada pode ser utilizada na detecção da presença de bordas, enquanto a segunda derivada pode ser utilizada para verificar em qual lado (de maior ou menor intensidade) encontra-se um pixel. Um dos elementos de importância na detecção de bordas é o vetor gradiente, que aponta na direção em que ocorrem mudanças mais abruptas dos tons de cinza da imagem. Seu cálculo baseia-se na obtenção de derivadas parciais que podem ser obtidas digitalmente de forma simplificada, o que permite o uso de máscaras para obtenção de seus valores pixel a pixel na imagem. O laplaciano também é bastante importante nesta atividade, sendo uma derivada de segunda ordem que também pode se calculada digitalmente de forma simplificada utilizando-se máscaras. O filtro Sobel é um dos operadores mais famosos para detecção de borda.

Difícilmente, o uso de um operador de derivação resultará em uma segmentação contínua e limpa das bordas da imagem. Normalmente, o que se obtém é uma gama de regiões desconexas que necessitam ser processadas para que a delimitação seja correta. Para tanto, pode-se utilizar processamento local através de máscaras que levem em consideração magnitude e ângulo do gradiente a fim de interligar as regiões desconexas.

Detecção de Fronteiras

Alternativamente às técnicas com máscaras, que são formas de processamento local, existe a possibilidade da detecção de bordas por processamento global. Duas formas de se realizar isso é através da transformada de Hough e do uso de grafos. A transformada de Hough mapeia os pontos da imagem em um espaço alternativo (chamado espaço de parâmetro) onde os pontos colineares são mapeados como curvas senoidais que se interceptam em um determinado ponto (cuja coordenada leva ao cálculo da reta que possui esse ponto no espaço da imagem). A transformada de Hough é útil, por exemplo, para a detecção de formas como segmentos de reta, círculos ou elipses em uma imagem.

A utilização de grafos consiste basicamente em representar os elementos da imagem na forma de um grafo ordenado, cujas arestas possuem pesos (ou custos). A busca por bordas nessa abordagem é basicamente a busca por um caminho de menor custo. A vantagem da utilização de representação por grafos é a alta tolerância a ruídos, porém o custo computacional é mais elevado que das técnicas abordadas anteriormente.

2.3.2 Limiarização

A limiarização é uma técnica de processamento global simples, porém rápida e poderosa, que constitui-se basicamente da partição do histograma em um ponto de valor T , onde todos os valores de cinza maiores que T assumem valor um e todos menores ou iguais a T assumem valor zero. Seja $f(x,y)$ uma imagem então $g(x,y)$, sua versão limiarizada, é dada por:

$$g(x,y) = \begin{cases} 1 & \text{se } f(x,y) > T \\ 0 & \text{se } f(x,y) \leq T \end{cases} \quad (2.7)$$

Essa técnica é utilizada para realizar uma segmentação rústica, separando a área de interesse do fundo. A principal desvantagem da limiarização é ser altamente influenciada

pela iluminação.

2.3.3 Orientação por Regiões

Ao contrário das técnicas mencionadas anteriormente, as técnicas orientadas por regiões visam discriminar as partes constituintes da imagem tendo diretamente como base as propriedades dos pixels e não bordas ou características globais (como valores de histograma). Nos sistemas orientados por regiões, estas devem seguir algumas propriedades como serem disjuntas, conexas, cobrirem toda a imagem original e seguirem um certo critério de pertinência determinado pelo algoritmo.

As duas técnicas mais conhecidas de segmentação baseada em regiões são a de Agregação de Pixels e Fusão de Regiões. Na agregação, o funcionamento básico é, tendo-se definido pontos iniciais (“sementes”), acrescentar pixels ao conjunto que originará a região segmentada; onde o critério de decisão é uma propriedade de semelhança definida pelo algoritmo, que pode ser por exemplo, cor, intensidade ou textura. O algoritmo deve iterar até que uma certa condição de parada seja atingida. Já na fusão de regiões, o funcionamento básico é subdividir a imagem em uma quantidade arbitrária de regiões disjuntas e depois iterar realizando fusões destas ou novas subdivisões, até que a condição de parada seja atingida.

2.4 Reconhecimento de Padrões na Segmentação Automática de Tumores do Encéfalo

A natureza das imagens de ressonância magnética e seus artefatos inerentes, aliados às características anatômicas presentes em imagens do encéfalo e eventuais alterações de sinal induzidas pela presença de tecido tumoral tornam a tarefa de segmentação uma atividade complexa, onde a utilização somente de técnicas simples de processamento de imagens muitas vezes mostra-se insuficiente. Devido a esse fato, a grande maioria dos trabalhos desenvolvidos buscando segmentar tumores de encéfalo em imagens médicas emprega técnicas de reconhecimento de padrões em algum momento do processo. Os diversos trabalhos presentes na literatura adotam configurações variadas, utilizando classificadores de aprendizado supervisionado, não-supervisionado ou estratégias mistas. A maior parte das publicações pesquisadas para este trabalho adotavam métodos estatísticos, porém métodos por redes neurais também são bastante frequentes.

Em (VAIDYANATHAN, 1997) foi explorado o uso de uma variação de aprendizado supervisionado do algoritmo fuzzy c-means (SFCM) para a segmentação de tumores de cérebro em imagens de ressonância magnética ponderadas em T1, T2 e PD. Seu objetivo era realizar uma medida objetiva da variação do volume tumoral durante o tratamento químico e rádio-terápico, buscando evitar a variabilidade de resultados encontrada entre as segmentações realizadas por diferentes indivíduos. Os resultados obtidos foram comparados com os resultados obtidos pelo algoritmo de k-vizinhos mais próximos (kNN), um algoritmo de crescimento de regiões (ISG-SG) e segmentação manual. Nesse trabalho, obteve-se uma taxa de reprodutibilidade da segmentação, intra-observador (diferentes segmentações de um mesmo observador), de 5,8% para o algoritmo SFCM, de 6,6% para o kNN e 6,5% para o ISG-SG. Já para o caso inter-observador (diferentes segmentações de diferentes observadores) obteve-se, respectivamente, 5,5%, 6,5%, e 11,4%. Verificou-se que os algoritmos kNN e SFCM apresentaram maior taxa de reprodutibilidade dos resultados, sendo considerados os mais aptos para realizar a tarefa considerada.

(FLETCHER-HEATH et al., 2001) utilizou o algoritmo fuzzy c-means de aprendizado não supervisionado como passo de pré-processamento em um sistema que incorpora características de sistemas baseados em conhecimento para a segmentação de tumores de cérebro não realçáveis em imagens por RM, mesmo após injeção de contraste. Nesse trabalho, o algoritmo de agrupamento (*clustering*) era o responsável por extrair o cérebro do restante da imagem e, posteriormente, por separar pixels que possivelmente pertencessem ao tecido tumoral. Como resultado, obteve-se uma taxa de correspondência entre o volume segmentado pelo sistema e o volume “padrão ouro”, de 53% à 90.9%, indicando que uma grande quantidade de pixels pertencentes à região tumoral foram corretamente identificados.

Em (KAUS et al., 2001) um método de classificação estatístico denominado pelos autores classificação adaptativa moderada por template (*adaptive template-moderated classification*), que engloba o uso do algoritmo k-vizinhos mais próximos, foi empregado na segmentação automática de tumores de cérebro em imagens por ressonância magnética. Esse trabalho obteve acurácia (por acurácia entende-se a exatidão da segmentação) média de 99,68% na segmentação automática dos tumores de cérebro, e a variabilidade inter-observador se manteve baixa, variando de 0,99% à 6,11%.

No trabalho de (MOON et al., 2002) os autores desenvolveram uma variante do algoritmo de maximização de expectativas (*expectation maximization - EM*) para segmentação de tecidos saudáveis e tumorais em imagens por ressonância magnética, levando em conta

dados de atlas estatísticos. O método apresentado nesse trabalho foi capaz de segmentar os tecidos normais juntamente com tumor e edema, utilizando dados de imagens ponderadas em T1 e T2. Os resultados obtidos apresentaram uma sobreposição de mais de 90% entre a região segmentada pelo sistema e a segmentação manual realizada por um médico.

Em (PRASTAWA et al., 2003) também foi explorado o uso do algoritmo de maximização de expectativa, utilizando dados de intensidade de imagens de RM ponderadas em T1 e T2, juntamente com dados de um template probabilístico “personalizado” para acomodar a probabilidade de existência de tumor dentro do conjunto de imagens de um paciente determinado. O objetivo desse trabalho foi novamente a segmentação de tecidos saudáveis juntamente com tecidos de tumor e edema. Os resultados obtidos foram comparados com um método de segmentação semi-automático, por *level-sets*, e com a segmentação manual da massa tumoral. O método automático foi capaz de segmentar a região tumoral, mas apresentou um resultado pior do que o método semi-automático.

Mais recentemente, em (CAI et al., 2007), os autores empregaram dados de modalidades padrão de ressonância (como T1 e T2) juntamente com modalidades mais modernas como DTI (*Diffusion Tensor Imaging*) com o objetivo de segmentar tecidos normais e tumorais. Os classificadores utilizados foram análise quadrática de discriminante (*quadratic discriminant analysis*) para teste intra-paciente (dados de treino e teste são provenientes de exames do mesmo paciente) e máquinas de vetor de suporte (*support vector machines*) para classificação de tecidos inter-paciente (provenientes de exames de diferentes pacientes). Ambos os algoritmos são de aprendizado supervisionado. No regime de teste intra-paciente (metade dos dados do paciente era usado para treinar o classificador, e a outra metade para testá-lo) a acurácia de acerto foi de 98,75% para edema, 96,53% para realçáveis por contraste, 96,73% para tumores não-realçáveis, e 99,85% para tecido saudável, quando comparado com segmentação realizada por um especialista. Já no regime de teste inter-pacientes (foram usados dados de diferentes pacientes para treinamento e teste) obteve-se acurácia de 98% para edema, e 73% para tumor realçável.

Já em (SHAHMORAD et al., 2007), os autores propuseram um método para segmentação automática de regiões de tumor em imagens também do tipo DTI. Nele, foi empregado um algoritmo de k-médias, de aprendizado não-supervisionado, para realização da segmentação automática. Nesse trabalho, realizou-se a comparação dos resultados com os obtidos por outro método computadorizado. Dentro deste contexto, o trabalho obteve 100% de acerto na segmentação.

Finalmente, em (RUAN et al., 2007) foi apresentada uma proposta de sistema cujo

objetivo era auxiliar no acompanhamento de tratamentos de tumores de cérebro, fornecendo uma ferramenta de segmentação automática para viabilizar o cálculo de volume dos tecidos. O sistema utiliza máquinas de vetor de suporte para segmentar imagens por RM ponderadas em T1, T2, PD e FLAIR, e os dados para classificação constituem-se em valores de intensidade, média e variância locais das imagens. Nesse trabalho, obteve-se 98,6% de positivos verdadeiros, 11,6% de falsos positivos e 1,4% de falsos negativos.

2.4.1 Aprendizado Supervisionado

Tipicamente, os algoritmos de aprendizado supervisionado possuem a tarefa de atribuir uma classificação a um padrão de entrada cuja classe é desconhecida, tendo como domínio um conjunto pré-definido de dados e respectivas classificações (JAIN; MURTY; FLYNN, 1999). Nesses algoritmos, que podem ser estatísticos ou por redes neurais, o modelo é primeiramente estimado durante o treinamento, que ocorre através de múltiplas apresentações de padrões de entrada juntamente com suas classes, pré-definidas por um tutor. A forma mais simples de classificação estatística por aprendizado supervisionado é utilizando-se aprendizado bayesiano (BEZDEK; HALL; CLARKE, 1993), onde a probabilidade à posteriori de se obter uma determinada classe ω_i dado um certo padrão pode ser obtida através da fórmula de Bayes:

$$P(\omega_i|x) = \frac{p(x|\omega_i)P(\omega_i)}{p(x)} \quad (2.8)$$

onde $p(x|\omega_i)$ é a função densidade probabilidade condicional, $P(\omega_i)$ é a função de probabilidade, e $p(x)$ a função densidade probabilidade fornecida por:

$$p(x) = \sum_{i=1}^n p(x|\omega_i)P(\omega_i) \quad (2.9)$$

sendo n o número de classes do problema.

Em um ambiente ideal, a probabilidade de ocorrência de uma classe poderia ser facilmente calculada por esse método, mas em ambientes reais as densidades de probabilidade condicionais raramente são conhecidas à priori, o que torna impossível a aplicação do aprendizado bayesiano diretamente. Ao longos dos anos de pesquisa nesta área, diversos algoritmos foram propostos, sendo paramétricos (exigem valores iniciais conhecidos) ou não paramétricos. Dentre os algoritmos mais conhecidos estão (DUDA; HART; STORK, 2001):

- máxima verossimilhança,

- k vizinhos mais próximos (*k nearest neighbor*),
- técnica dos mínimos quadrados,
- máquina de vetor de suporte,
- perceptrons multi-camada.

Sendo o último, um típico representante dos métodos de aprendizado supervisionado por redes neurais. Na literatura, pode-se encontrar diversos métodos derivados destes aqui citados, podendo alguns deles serem estendidos para o caso de aprendizado não-supervisionado.

2.4.2 Aprendizado Não-Supervisionado

Ao contrário dos algoritmos de aprendizado supervisionado, os algoritmos de aprendizado não-supervisionado, ou clusterização (*clustering*), lidam com problemas em que as classes dos padrões de entrada não são conhecidas, ou não estão definidas, e seu objetivo é agrupá-los em conjuntos que possuam algum sentido. Algoritmos de aprendizado não-supervisionado podem ser do tipo estatístico ou por redes neurais.

Os algoritmos de clusterização buscam agrupar os elementos em conjuntos de semelhantes, ou seja, em conjuntos onde os elementos possuam algum tipo de proximidade. Tal medida geralmente é obtida utilizando-se algum cálculo de distância. Entre as mais utilizadas para este fim estão (JAIN; MURTY; FLYNN, 1999):

- euclidiana,
- mahalanobis,
- vizinhança mútua (*Mutual Neighbor Distance*).

Entre os algoritmos de aprendizado não-supervisionado mais freqüentemente utilizados estão:

- algoritmo de erro quadrático,
- k -médias (*k-means*),
- *minimal spanning tree*,

- maximização de expectativa (*expectation maximization*),
- vizinho mais próximo (*nearest neighbor*),
- clusterização fuzzy,
- *learning vector quantization* (LVQ),
- mapas auto-organizáveis *self-organized maps* (SOM).

2.4.3 Seleção de Características

A tarefa de seleção de características, ou seleção de variáveis, consiste na escolha de um subconjunto de características a partir de um conjunto maior, de forma a reduzir a dimensionalidade de um problema de classificação; o que resulta em maior desempenho quando utilizada por algum sistema de classificação. Dentre os maiores benefícios dessa prática estão a melhora na visualização e entendimento dos dados, redução no espaço de armazenamento necessário, redução no tempo necessário para treino e testes do sistema, redução no problema de praga de dimensionalidade, e eventualmente, melhora na eficiência da classificação. Dentre as várias aplicações da seleção de característica estão a seleção de genes em *microarrays*, e classificação de textos para reconhecimento de *spam* (ZONGKER; JAIN, 1996; GUYON; ELISSEEFF, 2003).

Os algoritmos de seleção de características geralmente apresentam quatro passos básico:

1. geração do subconjunto,
2. avaliação do subconjunto,
3. verificação da condição de parada,
4. validação dos resultados.

No passo de geração de subconjunto, uma busca heurística é realizada, de forma a reunir características que serão em seguida avaliadas. Os métodos de busca mais utilizados são a busca completa, busca sequencial, e busca aleatória; e a avaliação dos subconjuntos é realizada por critérios dependentes ou independentes. Nos critérios dependentes um algoritmo de classificação é empregado para avaliar a qualidade do subconjunto; geralmente o algoritmo empregado é o mesmo em que os conjuntos de dados serão utilizados

mais tarde. Esse tipo de critério fornece os melhores resultados, mas é muito custoso computacionalmente. Já os critérios independentes buscam características inerentes ao conjunto de dados para avaliá-los. Alguns tipos comuns de critérios independentes são as medidas de distâncias (como euclidiana ou de mahalanobis), medidas de dependência (por exemplo, correlação), medidas de quantidade de informação e de consistências. Esses critérios são menos precisos, porém computacionalmente mais eficientes. O passo seguinte à avaliação é a condição de parada, que se não for atingida levará à geração de um novo subconjunto. O passo final é a validação dos resultados, onde se verifica a real utilidade do subconjunto gerado na atividade de classificação (LIU; YU, 2005).

Pode-se encontrar na literatura especializada uma vasta quantidade de algoritmos para seleção de características, que podem ser divididos em três tipos básicos:

- modelo de filtro,
- modelo *wrapper*,
- modelo híbrido.

Os modelos de filtro utilizam os critérios independentes e, conseqüentemente, são computacionalmente mais eficientes. Os modelos *wrapper* utilizam critérios dependentes, o que os torna mais precisos na busca por subconjuntos adequados a um determinado tipo de algoritmo de classificação, porém são computacionalmente mais dispendiosos. Já os modelos híbridos empregam as características dos modelos anteriores, realizando buscas com critérios dependentes e independentes, dependendo do estágio do processamento.

2.5 Análise de Texturas

Texturas são características inerentes à maioria dos objetos, e constituem um fator importante na discriminação de componentes de uma cena ou imagem. Em processamento de imagens, são amplamente utilizadas na análise e segmentação de imagens em diversas áreas como sensoriamento remoto (BACKES et al., 2007), automação industrial (FRI-COUT et al., 2008), processamento de imagens biomédicas (CASTELLANO et al., 2004) e também em sistemas de busca por conteúdo (SIDHU; RAAHEMIFAR, 2005). Em neurologia, a análise textural encontra algumas aplicações importantes como a caracterização de formas de tecidos e suas funcionalidades (ROCCHI et al., 2007), auxílio no tratamento de epilepsia (JAFARI-KHOUSANI et al., 2003), esclerose múltipla (ZHANG; WANG;

TONG, 2007) e Alzheimer (FREEBOROUGH; FOX, 1998), análise do tecido cerebral em busca de patologias difusas (KOVALEV et al., 2001) e segmentação e caracterização de tecido tumoral, entre outros.

Pode-se encontrar na literatura uma variedade de trabalhos que utilizam características extraídas de textura para análise e segmentação de tumores de cérebro. (SCHAD; BLUML; ZUNA, 1993) e (LERSKI et al., 1993) são dois trabalhos pioneiros no uso de informações texturais para caracterização e diferenciação entre tecidos tumorais e saudáveis, em imagens por RM. No primeiro foram aplicados parâmetros de textura estatísticos, juntamente com características de histograma e de gradiente, para a discriminação entre diferentes tecidos cerebrais. As regras inferidas a partir da análise de texturas de regiões de tumor, edema, líquido, substância branca (SB) e substância cinza (SC) foram incorporadas em um sistema especialista responsável por supervisionar a segmentação de imagens. Apesar de não apresentar resultados quantitativos sobre o sucesso da segmentação, o artigo mostrou ser possível utilizar características de textura para discriminar os diferentes tipos de tecido presentes em RMs de tumores de cérebro. Já em (LERSKI et al., 1993) os autores realizaram uma extensa revisão do estado-da-arte, da época, descrevendo algumas pesquisas cujo objetivo era aprimorar a aplicação de análise de texturas na caracterização de tecidos cerebrais, em imagens por RM.

Em (KJAER et al., 1995) o uso de informações de texturas na caracterização e diferenciação entre tecidos saudáveis e doentes foi revisitado, em um trabalho semelhante a (SCHAD; BLUML; ZUNA, 1993). Porém, nesse trabalho também foram consideradas informações de outras naturezas como os valores de intensidade dos pixels da imagem (que são utilizados após normalização das intensidades de cinza). As informações calculadas a partir de imagens ponderadas em T1 e T2 permitiram uma discriminação precisa entre os diferentes tecidos presentes nas imagens (tumor, SB, SC cortical e líquido).

(ZIZZARI; SEIFFERT; MICHAELIS, 2001) utilizou características de textura baseadas em matrizes de co-ocorrência (MCO) para segmentar imagens de glioblastomas multiformes em imagens de tomografia computadorizada, tendo como classificador redes SOM (*self-organizing maps*). O resultado obtido pela rede inicializava um algoritmo de detecção de bordas responsável por gerar a segmentação final do tumor. O melhor resultado obtido nesse trabalho foi de 85,3% de acerto por parte do classificador.

No trabalho de (MAHMOUD-GHONEIM et al., 2003) foram propostas e utilizadas matrizes de co-ocorrência (MCO) tridimensionais para analisar regiões de interesse em imagens de RM T1 sem contraste, de forma a averiguar sua maior eficiência em relação

às MCOs bidimensionais, na distinção entre diferentes tecidos. As classes utilizadas nesse trabalho foram: necrose, tumor sólido, edema, SB homolateral, SB contranatural e SB peritumoral, e o método de classificação utilizado foi análise de discriminante linear (*linear discriminant analysis - LDA*). Nesse trabalho foi possível discriminar com 100% de acerto entre necrose e tumor, e SB peritumoral e homolateral; com 82% de acerto entre tumor sólido e edema, e entre edema e SB peritumoral; e com 83% de acerto entre SB homolateral e contralateral. Em todos os casos as MCOs tridimensionais permitiram uma maior taxa de acerto quando comparadas com as bidimensionais.

Em (HERLIDOU-MÊME et al., 2003) avaliou-se primeiramente a dependência das características de texturas em relação aos parâmetros e condições de obtenção das imagens de RM, através da obtenção de imagens de RM T1 e T2 de objetos de teste em diferentes centros clínicos, utilizando diferentes protocolo. Em seguida, avaliou-se o uso destas na classificação de tecidos cerebrais (SB, SC, líquido, tumor e edema). As texturas utilizadas nesse trabalho foram do tipo estatístico, de primeira, segunda e terceira ordem. Nesse trabalho foi possível, utilizando-se características de texturas extraídas de imagens ponderadas em T2, obter uma classificação correta entre líquido, SB, SC, tumor e edema para 76% dos pacientes testados; de 52% entre SB, SC, tumor e edema; de 58% entre SC, edema e tumor; de 49% entre tumor e edema; e de 63% entre tumor benigno e tumor maligno. Já para características de textura extraídas de imagens ponderadas em T1, obteve-se respectivamente a seguintes taxas de acerto: 68%, 46%, 63%, 55% e 51%. Em nenhum dos casos foi possível discriminar entre diferentes tipos de tumor.

No trabalho de (IFTEKHARUDDIN; JIA; MARSH, 2003) mudou-se um pouco a estratégia, utilizando-se texturas fractais para localizar tumores de cérebro em imagens por RM. O enfoque deste trabalho foi a elaboração de novos algoritmos fractais capazes de extrair dados texturais de imagens, que sejam eficientes na segmentação de imagens. Esse trabalho é preliminar e não fornece uma análise quantitativa dos resultados. Porém, os autores mostram que o algoritmo proposto é capaz de apontar a existência de tumor na imagem, sem ser capaz de localizá-lo com precisão.

Em (SANTOS et al., 2004) foi quantificada a variabilidade de texturas entre tecidos supostamente sadios distantes do tumor e próximos a este, bem como de tecido tumoral, edema e líquido. Nele averiguou-se a capacidade das técnicas de análise de texturas diferenciarem entre tumor e tecido saudável, juntamente com o fato de haver significativa variabilidade entre os valores extraídos das regiões saudáveis próximas e distantes da lesão, sugerindo um possível comprometimento ainda não visualmente identificável do

tecido.

Já em (IFTEKHARUDDIN; ZHENG; ISLAM, 2006) os autores continuaram o trabalho com texturas fractais, desta vez aplicando-as na segmentação de tumores de cérebro infantis. Foram utilizadas imagens por RM ponderadas em T1, T2 e FLAIR; e redes SOMs, SVMs e redes neurais para classificação. Foram adicionadas informações sobre intensidade dos pixels para obter melhor resultado na segmentação. Nesse trabalho obteve-se uma taxa de acerto de 57% à 95% para segmentação com características extraídas de apenas uma modalidade de RM. Já para o processamento multi-modalidades obteve-se uma taxa de acerto de 100%.

No trabalho descrito em (SASIKALA; KUMARAVEL; SUBHASHINI, 2006) os autores utilizaram texturas estatísticas e por wavelets para segmentar glioblastomas multi-formes em imagens por RM. Para segmentação são testados o algoritmo de crescimento de região, fuzzy c-means (FCM) com o número de classes configurado para dois (tumor e não-tumor), e redes neurais. Um conjunto ótimo de características é selecionado através de algoritmo genético. A acurácia da segmentação por crescimento de regiões é de 94,29%, por FCM 94% e por rede neural 98,45%.

Finalmente, em (XUAN; LIAO, 2007) os autores utilizaram características baseadas em intensidade, simetria e texturas para realização da segmentação automática de tumores de cérebro em imagens por RM. A textura utilizada nesse trabalho é conhecida como descritor homogêneo de textura, extraído utilizando-se filtros de Gabor, e o classificador é o algoritmo chamado adaboost. Também foram testados o algoritmo de k-vizinhos mais próximos e máquina de vetor de suporte. O método descrito nesse trabalho obteve uma taxa de segmentação correta de 96,82%, com 1,3% de falsos positivos e 3,69% de falsos negativos.

A importância da análise de texturas em processamento de imagens se dá pelo fato da extração de características por meios matemáticos ser capaz de obter informações de forma quantitativa, e conseqüentemente objetiva, em imagens onde a percepção humana falha em registrar os detalhes (HERLIDOU et al., 1999; SANTOS et al., 2004). Estima-se que a visão humana tenha dificuldades na percepção de diferenças entre texturas que possuam semelhanças de estatística espacial de ordens superiores, mesmo quando estas diferem em primeira ordem (JULESZ, 1962), o que não ocorre com os métodos matemáticos. Define-se (TUCERYAN; JAIN, 1998):

1. Estatísticas espaciais de primeira ordem como a probabilidade de se observar um

pixel com um determinado valor de cinza em uma localização aleatoriamente escolhida de uma imagem. Sendo dependentes apenas dos valores individuais dos pixels e não da interação destes com os valores de pixels vizinhos.

2. Estatísticas espaciais de segunda ordem como a probabilidade de se observar um certo par de pixels com valores de cinza que possuem distância e orientação de localização aleatórias.

Porém, tal fato não é regra, existindo vários casos onde texturas com distribuições espaciais de baixa ordem diferentes e de alta ordem iguais que são facilmente diferenciadas pelo olho humano, sem que haja esforço intelectual para tanto. Esse fenômeno levou à descoberta da importância de agrupamentos de brilho semelhante na percepção visual de texturas (JULESZ, 1962), ou *textons*, eventos visuais cuja presença é facilmente identificada pela visão (TUCERYAN; JAIN, 1998; RANGAYYAN, 2005).

Na figura 2.15 tem-se três exemplos de texturas propostas por (JULESZ, 1962) para demonstrar a dificuldade de diferenciação de texturas por observadores humanos. Na primeira imagem (primeiro quadro, à esquerda) são apresentados dois campos aleatórios com primeira e segunda ordem idênticas, mas terceira ordem diferente. Na segunda imagem são apresentados dois campos aleatórios com primeira ordem diferente; e na última imagem dois campos aleatórios com primeira ordem idêntica mas segunda ordem diferente.

Figura 2.15: Texturas apresentadas em (JULESZ, 1962)

Texturas podem ser classificadas como (MARTINS, 1997; RANGAYYAN, 2005):

- periódicas (ou quase-periódicas): são texturas onde ocorre a repetição de um elemento (ou *texton*) de forma regular (ou quase regular),
- aleatórias: são texturas onde não é possível identificar um *texton*,

- orientadas: são texturas que apresentam comportamento direcionado em um certo ângulo.

Apesar de sua importância, não há um consenso sobre uma definição formal de textura. As definições existentes variam de acordo com o objetivo do trabalho desenvolvido. Nesse trabalho é adotada a definição encontrada no trabalho clássico de Haralick (HARALICK, 1979). Nela:

“a textura que nós consideramos é não-figurativa e celular[...]. Uma textura é descrita pela quantidade e tipos de primitivas (tonais)[...]. Uma característica fundamental da textura: não pode ser analisada sem que um quadro de referência da primitiva tonal seja declarado ou inferido. Para qualquer superfície suave em tons de cinza, existe uma escala tal que quando esta é analisada não existe textura. Então, a medida que a resolução aumenta, esta torna-se uma textura fina e depois grossa.”

A seguir, alguns dos métodos mais comuns para análise de texturas serão descritos, levando em consideração sua relevância para esse trabalho.

2.5.1 Métodos Estatísticos

A abordagem estatística para descrição de texturas realiza a caracterização destas através de regras que governam sua distribuição espacial e relação entre seus níveis de cinza (FLEURY, 2001). É uma das abordagens mais antigas da literatura, possuindo inúmeras técnicas de extração propostas (sendo muitas inter-relacionadas) (TUCERYAN; JAIN, 1998) e ainda hoje uma das mais utilizadas.

As medidas de textura mais simples podem ser obtidas baseando-se nos momentos da função densidade probabilidade (FDP) $p(i)$ (histograma normalizado) (RANGAYYAN, 2005), onde o k -ésimo momento de $p(i)$ é definido como:

$$m_k = \sum_{i=0}^{L-1} (i - \mu_f)^k p(i) \quad (2.10)$$

sendo L o número de tons de cinza da imagem f e μ_f o valor médio dos tons de cinza. A média é dada por:

$$\mu_f = \sum_{i=0}^{L-1} i p(i) \quad (2.11)$$

As medidas baseadas em FDP mais utilizadas são o segundo momento central, e o terceiro e quarto momentos normalizados. O segundo momento central é a variância dos tons de cinza e fornece uma medida de heterogeneidade da imagem. Podendo ser calculado como:

$$m_2 = \sigma_f^2 = \sum_{i=0}^{L-1} (i - \mu_f)^2 p(i) \quad (2.12)$$

Já o terceiro momento normalizado, ou coeficiente de assimetria, fornece uma medida de assimetria da FDP, sendo calculado por:

$$\text{coeficiente de assimetria} = \frac{m_3}{\sqrt{m_2^3}} \quad (2.13)$$

O quarto momento normalizado, ou curtose, fornece uma medida de uniformidade da FDP e pode ser calculado por:

$$\text{curtose} = \frac{m_4}{\sqrt{m_2^2}} \quad (2.14)$$

Tais medidas podem ser consideradas como medidas de textura de primeira ordem, uma vez que refletem a organização espacial dos pixels independentemente de seus vizinhos. É importante notar que momentos de alta ordem são significativamente sensíveis à presença de ruído, portanto pouco confiáveis, sendo utilizados apenas como uma caracterização básica do histograma da imagem (RANGAYYAN, 2005).

Matriz de co-ocorrência

Um dos trabalhos mais significativos na área de análise de texturas foi realizado por Robert Haralick na década de setenta, no artigo (HARALICK; SHANMUGAM; DINSTEN, 1973), onde foi proposto o uso de matrizes de co-ocorrência, das quais podem ser extraídas diversas características texturais. O trabalho de Haralick visava a aplicação em atividades de sensoriamento remoto como reconhecimento e classificação de diferentes tipos de rocha.

As matrizes de co-ocorrência foram criadas assumindo-se que a informação textural está, em média, espalhada pela imagem inteira, e que pode ser adequadamente especificada pelas frequências de ocorrência (P_{ij}) de um par de pixels que possua tons i e j , respectivamente, encontrando-se separados por uma distância d em um ângulo de θ graus (HARALICK; SHANMUGAM; DINSTEN, 1973; HARALICK, 1979). Formalmente, para uma imagem f , a entrada (i, j) da matriz é igual ao número de ocorrências de $f(x_1, y_1) = f(x_2, y_2)$ onde $(x_2, y_2) = (x_1, y_1) + (d \cos \theta, d \sin \theta)$. Se tal matriz for dividida

pelo número de pixels vizinhos $R(d, \theta)$ se tornará a probabilidade conjunta de ocorrência de dois pixels separados por uma distância d em uma direção θ possuírem valores de intensidade i e j , respectivamente (MATERKA; STRZELECKI, 1998). Neste caso, pode-se dizer que a matriz de co-ocorrências está normalizada. Um grande número de matrizes de co-ocorrência pode ser calculando, variando-se θ e d , porém o esforço computacional é proporcional ao número de pixels da imagem, e em alguns casos pode se tornar proibitivo. No artigo (HARALICK; SHANMUGAM; DINSTEN, 1973) os autores recomendam o uso de $d = 1$ e dos ângulos 0° , 45° , 90° e 135° . Abaixo estão listados os parâmetros que podem ser extraídos das matrizes de co-ocorrência segundo eles:

- Segundo Momento Angular (SMA)

$$f_1 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} [p(i, j)]^2 \quad (2.15)$$

- Contraste

$$f_2 = \sum_{n=0}^{N_g-1} n^2 \left[\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \right], \text{ com } |i - j| = n \quad (2.16)$$

- Correlação

$$f_3 = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (ij) p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (2.17)$$

- Variância

$$f_4 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - \mu)^2 p(i, j) \quad (2.18)$$

- Momento de Diferença Inverso (MDI)

$$f_5 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1 + (i - j)^2} p(i, j) \quad (2.19)$$

- Média da Soma (MS)

$$f_6 = \sum_{i=2}^{2N_g} i p_{x+y}(i) \quad (2.20)$$

- Variância da Soma (VS)

$$f_7 = \sum_{i=2}^{2N_g} (i - f_6)^2 p_{x+y}(i) \quad (2.21)$$

- Entropia da Soma (ES)

$$f_8 = - \sum_{i=2}^{2N_g} p_{x+y}(i) \log[p_{x+y}(i) + \epsilon] \quad (2.22)$$

- Entropia

$$f_9 = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \log[p(i, j) + \varepsilon] \quad (2.23)$$

- Variância da Diferença (VD)

$$f_{10} = f_4[p_{x-y}(i)] \quad (2.24)$$

- Entropia da Diferença (ED)

$$f_{11} = - \sum_{i=0}^{N_g-1} p_{x-y}(i) \log[p_{x-y}(i) + \varepsilon] \quad (2.25)$$

- Medidas de Correlação por Informação (MCI)

$$f_{12} = \frac{HXY - HXY1}{\max[HX, HY]} \quad (2.26)$$

$$f_{13} = \sqrt{1 - \exp[-2(HXY2 - HXY)]} \quad (2.27)$$

onde HX e HY são entropias de $p_x(\cdot)$ e $p_y(\cdot)$ e

$$HXY = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \log[p(i, j)] \quad (2.28)$$

$$HXY1 = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \log[p_x(i)p_y(j) + \varepsilon] \quad (2.29)$$

$$HXY2 = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p_x(i)p_y(j) \log[p_x(i)p_y(j) + \varepsilon] \quad (2.30)$$

- Coeficiente de Correlação Maximal (CCM)

$$f_{14} = \sqrt{\text{segundo maior autovalor de } Q} \quad (2.31)$$

onde

$$Q(i, j) = \sum_{k=1}^{N_g} \frac{p(i, k)p(j, k)}{p_x(i)p_y(k)} \quad (2.32)$$

Matrizes *run-length*

Outro método estatístico relativamente conhecido é baseado nas matrizes *run-length* ou de carreira. Seu conceito foi formulado partindo-se do princípio que texturas de menor granularidade contêm maior quantidade de carreiras de tons de cinza curtas e texturas de maior granularidade contêm carreiras longas. Uma matriz $p(i, j)$ de carreira relaciona

a quantidade de carreiras de pixels de um certo tom i e comprimento j , ou seja, uma posição (i, j) da matriz armazena o número de carreiras de comprimento j cujo tom seja i .

A partir da matriz podem ser calculados cinco parâmetros básicos de descrição de textura (TANG, 1998):

- Ênfase em carreiras curtas (*Short run emphasis* - SRE)

$$f_1 = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i, j)}{j^2} \quad (2.33)$$

- Ênfase em carreiras longas (*Long run emphasis* - LRE)

$$f_2 = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N P(i, j) j^2 \quad (2.34)$$

- Ênfase em carreiras de níveis de cinza baixos (*Low gray-level run emphasis* - LGRE)

$$f_3 = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i, j)}{i^2} \quad (2.35)$$

- Ênfase em carreiras de níveis de cinza altos (*High gray-level run emphasis* - HGRE)

$$f_4 = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N P(i, j) i^2 \quad (2.36)$$

- Ênfase em carreiras curtas de níveis de cinza baixos (*Short run low Gray-level emphasis* - SRLGE)

$$f_5 = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i, j)}{i^2 j^2} \quad (2.37)$$

As características originais extraídas das matrizes de carreira apresentam uma série de falhas, sendo a principal delas levar em conta apenas as informações quantitativas sobre a ocorrência de carreiras de tom, sem que seja levado em conta os tons de cinza em si. No trabalho apresentado em (CHU; SEHGAL; GREELEAF, 1990) duas novas características são propostas com o intuito de extrair informações texturais a partir das matrizes de carreira levando-se em conta tais tons de cinza, complementando a informação obtida pelos descritores originais. Estas duas novas características são:

- Ênfase em carreiras curtas de níveis de cinza altos (*Short run high gray-level empha-*

sis - SRHGE)

$$f_6 = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i, j) i^2}{j^2} \quad (2.38)$$

- Ênfase em carreiras longas de níveis de cinza baixos (*Long run low gray-level emphasis* - LRLGE)

$$f_7 = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i, j) j^2}{i^2} \quad (2.39)$$

Já o trabalho apresentado em (DASARATHY; HOLDER, 1991) propõe quatro novos descritores capazes de enfatizar a distribuição conjunta de números de carreiras e tons de cinza:

- Ênfase em carreiras longas de níveis de cinza altos (*Long run high gray-level emphasis* - LRHGE)

$$f_8 = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N P(i, j) i^2 j^2 \quad (2.40)$$

- Não-uniformidade de níveis de cinza (*Gray-level non-uniformity* - GLN)

$$f_9 = \frac{1}{n_r} \sum_{i=1}^M \left[\sum_{j=1}^N P(i, j) \right]^2 \quad (2.41)$$

- Não-uniformidade de comprimento de carreira (*Run-length non-uniformity* - RLN)

$$f_{10} = \frac{1}{n_r} \sum_{j=1}^N \left[\sum_{i=1}^M P(i, j) \right]^2 \quad (2.42)$$

- Porcentagem de carreiras (*Run percentage* - RP)

$$f_{11} = \frac{n_r}{P(i, j) j} \quad (2.43)$$

2.5.2 Métodos Estruturais

Como já foi mencionado anteriormente, a presença de primitivas (ou *textons*) realiza um papel importante na percepção de diferentes texturas. Métodos de descrição estruturais baseiam-se na idéia de modelar texturas através de seus *textons* e respectivas regras de posicionamento sobre a superfície, principalmente para texturas periódicas (RANGAYYAN, 2005). Os algoritmos utilizados nesse método realizam dois passos básicos:

1. inferência da primitiva,
2. inferência da regra de posicionamento.

A utilidade desses métodos na análise de texturas é baixa, sendo mais eficiente na síntese de texturas (MATERKA; STRZELECKI, 1998; TUCERYAN; JAIN, 1998), e portanto, não será considerada nesse trabalho.

2.5.3 Métodos Baseados em Modelo

A modelagem de imagens envolve a construção de modelos e/ou procedimentos matemáticos capazes de especificá-las, podendo estes serem utilizados tanto na síntese de imagens semelhantes como em sua descrição ou análise (CROSS; JAIN, 1983). Partindo desse princípio, os métodos baseados em modelo procuram modelar as texturas presentes em uma imagem utilizando modelos matemáticos pré-definidos e estimando seus parâmetros. Tais parâmetros podem ser utilizados diretamente como descritores de textura, ou podem ser utilizados para obtenção de descritores diversos. Esses métodos trabalham assumindo o valor de um ponto da textura como dependente de uma vizinhança com tamanho pré-definido (RANDEN; HUSOY, 1999; CLAUSI; YUE, 2004). Os métodos mais comuns de análise de textura baseada em modelo são a modelagem estocástica e a modelagem por fractal (MATERKA; STRZELECKI, 1998).

Modelos Markovianos

Nesse tipo de modelagem a premissa básica é a existência de uma dependência estatística dada por um Campo Aleatório de Markov (ou *Markov Random Field - MRF*), entre os valores dos tons de cinza de pontos dentro de uma certa vizinhança da imagem (CROSS; JAIN, 1983). MRFs são populares para a modelagem de imagens, uma vez que são capazes de capturar a informação contextual espacial (TUCERYAN; JAIN, 1998).

Definição de Campo Aleatório: Seja $X = \{X_1, X_2, \dots, X_n\}$ um vetor de variáveis aleatórias, $\Omega = \{1, 2, \dots, N\}$ um espaço amostral, e $x = \{x_1, x_2, \dots, x_n\}$ uma realização de X em Ω . Sendo P uma medida de probabilidade em Ω , se $P(x) > 0, \forall x \in \Omega$ então x é denominado **campo aleatório**. Sendo assim, defini-se Campo Aleatório de Markov como: O campo aleatório P é um MRF a respeito de uma vizinhança ∂ se para todo $x = \{x_1, x_2, \dots, x_n\} \in \Omega$

$$P(X_s = x_s | X_t = x_t, t \neq s) = P(X_s = x_s | X_t = x_t, t \in \partial_s)$$

Ou seja, as características locais em um MRF dependem apenas da vizinhança.

Na maioria dos trabalhos, salvo diferenças de notação, uma imagem é considerada um reticulado L , de dimensões $M \times N$, tal que $L = (i, j) | 1 \leq i \leq M, 1 \leq j \leq N$, com $I(i, j)$ uma variável aleatória que representa o tom de cinza do ponto (i, j) no reticulado. Pode-se atribuir a I diferentes tipos de distribuições. Por exemplo, o trabalho de (CROSS; JAIN, 1983) assume uma distribuição binomial para seu MRF, enquanto o trabalho de (MANJUNATH; CHELLAPPA, 1991) assume uma distribuição gaussiana. As vizinhanças de um ponto (i, j) também podem ser definidas de diversas formas, sendo os vizinhos de primeira ordem, os vizinhos 4-conexos de (i, j) e, de segunda ordem, os 8-conexos, podendo haver ordens maiores. Na figura 2.16, tem-se a organização espacial das vizinhanças de diferentes ordens, para um certo ponto s . Geralmente, sub-áreas conexas (chamadas *cliques*) com pontos unitários, duplas, triplas, ou quadruplas dessas vizinhanças são consideradas para a estimativa dos parâmetros das distribuições. Na figura 2.17, tem-se exemplos de alguns tipos de cliques.

5	4	3	4	5
4	2	1	2	4
3	1	s	1	3
4	2	1	2	4
5	4	3	4	5

Figura 2.16: Vizinhanças de 1^a , 2^a , 3^a , 4^a , e 5^a ordem, para o ponto s

Figura 2.17: Cliques de uma vizinhança de segunda-ordem (TUCERYAN; JAIN, 1998)

Um MRF também pode ser descrito como um Campo de Gibbs (MUSGRAVE; QUINN, 1995), sendo:

$$p(d) = \frac{e^{-U(d)}}{Z} \quad (2.44)$$

onde d é uma realização de Ω , $U(\cdot)$ uma função de energia, e Z uma função de normalização. Diferentes definições de $U(\cdot)$ levam a diferentes tipos de MRF, como gaussiano, binomial e gibsoniano. A estimação dos parâmetros desse modelo originam as características de textura que poderão ser utilizadas nas tarefas de análise de texturas. Tal estimativa pode ser realizada por diferentes algoritmos como Máxima Verossimilhança ou Método dos Mínimos Quadrados. A escolha do algoritmo pode fornecer maior ou menor precisão, tendo como pena o custo computacional que muitas vezes é alto.

Modelos Fractais

A geometria fractal é uma extensão da geometria euclidiana, criada por Benoit Mandelbrot em 1975, capaz de representar mais eficientemente elementos naturais. Fractais são estruturas que apresentam características de Sistemas Dinâmicos, sendo vulgarmente conhecidos como elementos recursivos que possuem auto-similaridade. Muitos processos físicos produzem superfícies fractais, sendo bastante comuns na natureza. Além disso, superfícies geradas por modelos fractais assemelham-se bastante a superfícies naturais (PENTLAND, 1984).

Matematicamente falando, um fractal é uma estrutura que apresenta dimensão de Hausdorff (ou Dimensão Fractal) estritamente menor que a sua dimensão Euclidiana (BARNSELY, 1988). A dimensão fractal está relacionada à noção intuitiva de “asperidade” de uma superfície (PENTLAND, 1984), fato que motiva o uso dessa grandeza como característica extraída na análise de texturas.

De forma simplificada, um fractal perfeito, entre outras características, apresenta a mesma forma sob qualquer escala. Sendo assim, um fractal perfeito pode ser decomposto em N cópias idênticas de si, reduzidas em um fator s . Pode dizer então que $N(s) \propto s^{-D}$, onde D é a dimensão fractal. D pode ser calculado por (VARMA; GARG, 2007):

$$D = \frac{-\log(N)}{\log(s)} \quad (2.45)$$

Existem diversos métodos para o cálculo da dimensão fractal, como *box-counting*, *box-counting* modificado, Área de Superfície de Prisma Triangular (*Piecewise Triangular Prism Surface Area - PTPSA*), entre outros. Esse último é utilizado em um trabalho recente apresentado em (IFTEKHARUDDIN; ZHENG; ISLAM, 2006) para detecção de tumores de cérebro em RM, através do uso de texturas. No algoritmo PTPSA, a imagem é dividida em subimagens de tamanho rxr (ver figura 2.18) e a intensidade de cada canto da sub-imagem (P1,P2,P3 e P4 da figura) é considerada uma altura. A intensidade média

Figura 2.18: Algoritmo PTPSA (IFTEKHARUDDIN; ZHENG; ISLAM, 2006)

dos quatro pixels dá a altura de P_c , considerado o centro da sub-imagem. A partir dessa configuração, pode-se montar quatro triângulos (ABE, BCE, CDE e DAE). A distância fractal nessa formulação é calculada como:

$$D = \frac{\log(S_{ADE} + S_{ABE} + S_{BCE} + S_{CDE})}{\log(r)} \quad (2.46)$$

onde S é a área do triângulo.

2.5.4 Métodos Baseados em Processamento de Sinais

A forma do sistema visual humano processar imagens pode ser modelada como um conjunto de detectores e filtros espaciais passa-faixa, onde cada par detector/filtro constitui um canal especializado em uma certa faixa de frequências; e cada canal opera independentemente (CAMPBELL; ROBSON, 1968). Analogamente, pode-se processar informações de imagens digitais, incluindo texturas.

Figura 2.19: Passos básicos para extração de características

As técnicas de análise de textura baseadas em processamento de sinais extraem informações da resposta obtida após um processo de filtragem e cálculo da energia local. Tais técnicas pressupõem que a distribuição de energia no domínio da frequência identificam

as texturas da imagem. Portanto, se for possível decompor o espectro da imagem em um número suficiente de sub-bandas cada textura possuirá uma assinatura espectral diferente, o que possibilitará sua identificação (RANDEN; HUSOY, 1999). A figura 2.19 ilustra os passos básicos para extração de informação utilizando-se processamento de sinais. Nela, pode-se ver que a função energia engloba os processos de não-linearidade e suavização que são utilizados, respectivamente para retificação do sinal e balanceamento da quantidade de resolução espacial *versus* resolução espectral do resultado. As características são extraídas do sinal resultante de todo o processo. É muito comum o uso de bancos de filtro nesse tipo de análise (RANDEN; HUSOY, 1999). Uma das vantagens do uso desse tipo de método é a possibilidade de análise multi-resolução.

Filtros de Gabor

Uma função bi-dimensional de Gabor no domínio espacial é definida como a multiplicação de uma função portadora senoidal $s(x,y)$ e um envelope gaussiano $g(x,y)$:

$$h(x,y) = s(x,y)g(x',y') \quad (2.47)$$

Sendo $s(x,y)$ definido como:

$$s(x,y) = e^{j2\pi(u_0x+v_0y)} \quad (2.48)$$

e $g(x,y)$ como:

$$g(x,y) = \frac{1}{2\pi\lambda\sigma^2} e^{-\frac{(\frac{x}{\lambda})^2+y^2}{2\sigma^2}} \quad (2.49)$$

Onde (x',y') representa as coordenadas (x,y) rotacionadas em um determinado ângulo:

$$(x',y') = (x\cos\theta + y\sin\theta, -x\sin\theta + y\cos\theta) \quad (2.50)$$

A função complexa de Gabor é definida por seus parâmetros:

- (u_0, v_0) : centro da gaussiana, no domínio da frequência,
- λ : define o formato da janela da gaussiana,
- θ : ângulo de rotação,
- σ : desvio padrão da gaussiana.

Um filtro de Gabor é caracterizado por uma função de Gabor com ângulo e frequência fixos, que age como um filtro passa-banda local. Normalmente, utilizam-se bancos formados por funções de diferentes ângulos e frequências, de forma a permitir a extração de

diversas características locais da imagem. A aplicação do filtro é realizada convoluindo-se a imagem em questão com a função de Gabor escolhida. O resultado é uma imagem que apresenta os valores das características desejadas (GRIGORESCU; PETKOV; KRUIZINGA, 2002). Os filtros de Gabor são boas ferramentas para localização de padrões orientados em imagens.

Existe uma gama de características que podem ser extraídas das imagens filtradas. Em (JAIN; FARROKHNI, 1990), por exemplo, após a filtragem um valor de “energia de textura” local é calculado através da equação 2.51:

$$e_k(x,y) = \frac{1}{M^2} \sum_{(a,b) \in W} |\psi(I(a,b))| \quad (2.51)$$

Sendo W uma janela quadrada centralizada em (x,y) . $I(x,y)$ a imagem resultante da filtragem e $\psi(\cdot)$ uma não-linearidade.

Wavelets

Wavelets são basicamente funções obtidas a partir de uma função “mãe” por meio de deslocamentos e reescalamentos (dilatações ou contrações). A forma geral de uma família de wavelets é dada por:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (2.52)$$

onde $\psi(t)$ é a função mãe, a o fator de escalamento e b fator de translação. Tais funções formam uma base capaz de descrever outras funções no espaço $L^2(\mathbb{R})$, espaço de todas as funções quadraticamente integráveis (classe de funções importante por abrigar a maior parte dos sinais reais relevantes para tarefas de processamento de sinais) (FARIA, 1997). As wavelets permitem analisar sinais de acordo com uma escala empregada. Através do uso de versões escaladas e deslocadas de uma wavelet mãe é possível realizar uma análise multi-resolução. Por exemplo, utilizando-se uma versão contraída, de alta frequência, de $\psi(t)$, pode-se realizar uma análise temporal do sinal; já utilizando-se uma versão dilatada, de baixa frequência, de $\psi(t)$, pode-se realizar uma análise em frequências do mesmo sinal. Como o sinal original pode ser representado por uma combinação linear das funções wavelet, as operações realizadas neste necessitam apenas dos coeficientes lineares da combinação (GRAPS, 1995). As características matemáticas das wavelets permitem que estas representem sinais com descontinuidades abruptas de forma mais precisa do que os senos e cossenos utilizados em Análise de Fourier, tornando-as mais versáteis para aplicações de processamento de sinais em geral. A aplicação de wavelets

aos dados geralmente é feita através de bancos de filtros. Os coeficientes lineares podem ser considerados como filtros, e são organizados em dois conjuntos. O primeiro formando um filtro passa-baixas (suavizador), e o segundo um filtro passa-altas (aguçador). Pode-

Figura 2.20: Canais de uma imagem filtrada por wavelets, e exemplo de uma imagem filtrada por uma db4 (família Daubechies)

se encontrar diversas famílias de wavelets na literatura, entre as mais frequentes estão (FARIA, 1997; GONZALEZ; WOODS; EDDINGS, 2004):

1. Haar,
2. Daubechies,
3. Coiflets,
4. Symlets,
5. Meyer,
6. Biortogonal.

Na figura 2.20, pode-se ver o resultado de uma imagem filtrada por wavelets. A subimagem HH representa detalhes com alta frequência nas duas dimensões (“cantos” da imagem), HL fornece altas frequências horizontais (arestas verticais), LH fornece altas frequências verticais (arestas horizontais), e LL fornece as frequências mais baixas. A análise pode prosseguir sempre filtrando a parte LL da imagem resultante e preservando os outros quadrantes, até que se obtenha o número de decomposições desejado (MATERKA; STRZELECKI, 1998).

Na análise de texturas, wavelets são utilizadas para decompor a imagem em um conjunto de canais independentes de diferentes frequências espaciais orientadas. As características de textura propriamente ditas são extraídas das imagens resultantes dos processos

de filtragem. Existem diversas formas de extrair características de texturas no método por wavelets. Por exemplo, em (SIDHU; RAAHEMIFAR, 2005) e (ARIVAZHAGAN; GANESAN, 2003) um método híbrido de wavelets com características estatísticas é explorado. Já (LI et al., 2003) explora o método convencional de extrair os valores de energia das imagens processadas.

2.6 Conclusão

Neste capítulo, foi resumido o estado-da-arte em técnicas para obtenção de imagens por Ressonância Magnética, bem como as técnicas para tratamentos de artefatos, segmentação, reconhecimento de padrões e análise de texturas. São também apresentados os conceitos básicos necessários para que o trabalho aqui proposto seja compreendido. No próximo capítulo será exposta a proposta para a criação de um sistema para a segmentação de tumores do encéfalo, tendo como base a classificação de características extraídas de texturas das imagens.

3 Proposta de um Sistema para Segmentação de Tumores do Encéfalo

O objetivo deste trabalho é a concepção de um sistema para segmentação de tumores de encéfalo em imagens por ressonância magnética, com base em duas premissas:

- a presença de células tumorais no tecido altera os tempos de relaxamento da ressonância magnética, alterando assim o sinal captado (GARCÍA; MORENO, 2004; ZHANG; MA; ER, 2004).
- a alteração no sinal causa alterações texturais, que mesmo que sejam visualmente imperceptíveis, podem ser detectadas por métodos matemáticos (SANTOS et al., 2004).

Estas afirmações indicam o bom potencial das informações de textura quando utilizadas como ferramentas na segmentação de tumores do encéfalo.

Os descritores (ou parâmetros) de textura geralmente são aplicados na segmentação de tumores encefálicos através do uso de algoritmos de reconhecimento de padrões, que os utilizam como características para classificação dos pixels do exame. Tais descritores podem ser usados como características principais durante o processo de classificação, ou como características coadjuvantes, complementadas por informações de outras naturezas, como valores de intensidade dos pixels, ou probabilidades provenientes de um atlas estatístico.

O sistema proposto considera imagens de RM comuns à rotina médica, como as ponderadas em T1, T1 com contraste e FLAIR, de forma a permitir o processamento “multicanal” de informações. Cada modalidade de ressonância funciona como um canal de informação diferente, uma vez que cada tipo de imagem é especializada em captar melhor determinadas características dos tecidos. As imagens T1, por exemplo, apresentam

maior sinal em regiões onde há maior concentração de gordura, as imagens FLAIR são melhores na captação de sinal proveniente de regiões onde há mais água; e as imagens T1 com contraste captam maior sinal onde há rompimento da barreira hematoencefálica. É importante ressaltar que essa formulação é flexível o suficiente para permitir a adoção futura de outros tipos de imagens, como RMs com tensor de difusão.

3.1 Etapas do Sistema

O sistema proposto é composto por quatro etapas: pré-processamento, extração de características, segmentação e pós-processamento. Cada etapa é composta por um ou mais processos.

Figura 3.1: Etapas e respectivos processos do sistema

Na figura 3.1, tem-se uma visão geral do fluxo de processamento, não levando em conta diferenças entre as fases de treinamento e teste do classificador. O sistema tem início na etapa de pré-processamento, sendo a segmentação efetivamente realizado durante a etapa de segmentação, onde há a separação dos pixels em duas classes: tumor e não-tumor.

3.2 Pré-processamento

A etapa de pré-processamento é importante pois prepara a imagem de forma a permitir que um melhor resultado seja obtido nas etapas seguintes. Os tipos de processamento realizados nessa fase são dependentes do objetivo da aplicação (GONZALEZ; WOODS,

2000). Técnicas como atenuação de ruído, normalização de histograma, correção de brilho e contraste, entre outras, são exemplos de processamentos que podem ocorrer nessa fase. Na proposta aqui descrita são utilizados sub-processos comumente adotados em trabalhos correlatos encontrados na literatura.

Essa é a etapa mais extensa e trabalhosa do sistema, pois deve lidar com os diversos artefatos inerentes às imagens de ressonância magnética, como ruído, falta de padronização de intensidades e presença de heterogeneidades do campo magnético.

3.2.1 Correção de Heterogeneidade

Como foi exposto no capítulo 2, a presença de heterogeneidades em imagens de ressonância deteriora a qualidade das informações contidas nestas, prejudicando a eficiência dos métodos de segmentação computadorizados. Consequentemente, o tratamento desse artefato, por vezes, torna-se mandatório para que um bom resultado seja obtido. A inclusão de correção de heterogeneidades na etapa de pré-processamento tem o intuito de melhorar o resultado da segmentação final. O algoritmo adotado é conhecido como N3 (*N3 - Nonparametric intensity Nonuniformity Normalization*), que é detalhadamente descrito em (SLED; ZIJDENBOS, 1998). Dentre as vantagens que levaram à escolha deste algoritmo estão:

- método não-paramétrico: o algoritmo não necessita de uma modelagem inicial das propriedades matemáticas dos tecidos imageados, nem de segmentações pré-definidas destes;
- independência de protocolo: o algoritmo é capaz de corrigir não-uniformidades de intensidade independentemente dos parâmetros utilizados durante a aquisição das imagens;
- treinamento desnecessário: o algoritmo não necessita de nenhum treinamento prévio para ser utilizado.

3.2.2 Suavização de Ruído

A suavização do ruído visa melhorar a capacidade de segmentação geral do sistema, através da melhora da relação sinal-ruído. O algoritmo escolhido para tratar o ruído de imagens de ressonância magnética deve proporcionar (GERIG et al., 1992):

- aguçamento de descontinuidades,
- remoção eficiente de ruído em regiões que contêm propriedades físicas heterogêneas,
- minimização da perda de dados através da preservação de bordas,
- independência de segmentação prévia,
- independência de conhecimento a priori do tecido imageado.

Na proposta aqui descrita, optou-se pela Difusão Anisotrópica para a suavização do ruído.

Esse algoritmo foi projetado para uso geral na redução de ruído de imagens, tendo como objetivo a suavização intra-regiões, preservação e aguçamento das bordas. Por ser um algoritmo maduro, bastante empregado em trabalhos de processamento de imagens, e por suprir as necessidades citadas acima, sua adoção é uma opção bastante razoável para este sistema. Uma descrição detalhada da Difusão Anisotrópica é encontrada em (PERONA; MALIK, 1990).

3.2.3 Registro

O registro de imagens é o processo onde duas ou mais imagens de um mesmo objeto (ou cena) de interesse são geometricamente alinhadas e sobrepostas. Geralmente, tais imagens são obtidas em diferentes instantes, através de diferentes sensores e com alguma variação no ângulo de obtenção. O uso de registros de imagens permite a obtenção de uma maior quantidade de informações através da combinação de diferentes modalidades de imageamento, e é muito comum em atividades como sensoriamento remoto, cartografia e imageamento médico (ZITOVÁ; FLUSSER, 2003), sendo esse último de maior interesse para o presente trabalho.

O objetivo do uso de registro de imagens neste trabalho é possibilitar a extração “multicanal” de características, ou seja, a extração de informações referentes a um pixel, provenientes de sinais de naturezas distintas. As fatias de imagens de RM das diferentes modalidades serão registradas, permitindo assim a inferência de relações diretas entre pixels pertencentes às diferentes imagens, mas localizados nas mesmas regiões anatômicas do encéfalo.

Pode-se encontrar na literatura diversos métodos de registro de imagens, desde os mais simples até os mais complexos. Neste trabalho será adotado um método de registro relativamente simples, baseado em médias locais ponderadas (GONZALEZ; WOODS;

EDDINGS, 2004), que permite o registro das imagens a partir de pontos de controle pré-definidos pelo usuário. Esse método é simples e computacionalmente eficiente, e fornece resultados satisfatórios, o que torna sua adoção uma escolha atraente para este trabalho.

3.2.4 Remoção do Tecido Extra-encefálico e Fundo

O objetivo da remoção do tecido extra-encefálico e do fundo é o aumento na velocidade geral do sistema através da redução do número de pixels que deverão ser processados. Neste processo é realizada uma pré-segmentação do encéfalo, separando este do restante da imagem. Como resultado, obtém-se uma máscara que permite a restrição da ação do sistema somente sobre os pixels de interesse, pertencentes à área de tecido cerebral. O método de extração de caixa craniana adotado nesta proposta é de formulação própria, e foi intitulado de Extração Semi-automática de Tecido Encefálico. A seguir é fornecida uma descrição detalhada do mesmo.

Extração Semi-automática de Tecido Encefálico

Esse método gera uma estimativa inicial da área do encéfalo, que é então utilizada na inicialização de um algoritmo de contornos ativos, responsável pela segmentação detalhada da região cerebral. Sua elaboração teve o objetivo de criar um algoritmo capaz de suprir as necessidades deste trabalho, sendo computacionalmente eficiente e de rápida implementação. Algoritmos mais precisos e robustos podem ser encontrados na literatura, porém, como o foco deste trabalho não está no pré-processamento, optou-se por um método menos elaborado, mas que fornecesse resultados suficientemente acurados para que pudesse ser aplicado.

Este algoritmo foi inspirado nos trabalhos de Brummer (BRUMMER et al., 1993) e Shen (SHEN; GRANAT, 2003), que tiraram proveito de características do histograma e de operações morfológicas para criar métodos para segmentação da área do cérebro, em imagens de ressonância magnética.

Os histogramas de imagens de RM do encéfalo apresentam um formato bem característico, que não varia muito entre diferentes exames. Apresentam um pico na região de baixa intensidade, que corresponde aos pixels de fundo (como pode ser visto na figura 3.2), e assumem formato unimodal ou bimodal na região mediana (ver figuras 3.2 e 3.3), correspondente aos pixels dos tecidos. As regiões do final do histograma (altas intensidades) normalmente correspondem ao ruído (NYUL; UDUPA, 1999).

Figura 3.2: Exemplo de histogramas com pixels de fundo. À esquerda: histograma bimodal, à direita: histograma unimodal

Figura 3.3: Histogramas bimodal e unimodal, sem pixels de fundo (NYUL; UDUPA, 1999).

O primeiro passo do algoritmo é o ajuste de contraste da imagem, que é realizado por uma função sigmoideal. Isso comprime as extremidades do histograma, fazendo com que a região de ocorrência de fundo (porção inicial) e ruído (porção final) tenham valor zero e um, respectivamente, tornando fácil sua remoção. O passo seguinte é o cálculo do valor de limiar utilizado na binarização da imagem. Nele, realiza-se o ajuste de uma curva gaussiana, cuja média é dada pelo pico do histograma resultante do passo anterior. O limiar é calculado como duas vezes o desvio padrão da curva obtida, como descrito em (BRUMMER et al., 1993). Esse valor normalmente é suficiente para remover boa parte dos artefatos de fundo e de estruturas como as meninges, restando o encéfalo e o crânio. Em seguida, operações morfológicas são aplicadas para desligar o encéfalo das estruturas adjacentes. Como o encéfalo normalmente é a maior estrutura conexa da imagem, a imagem é filtrada para remoção de estruturas conexas menores. O resultado

dessa operação é utilizado na inicialização de um contorno ativo.

O algoritmo de contorno ativo adotado é descrito em (CHAN; VESE, 2001). Sua aplicação permite a obtenção de uma segmentação mais refinada do que utilizando-se apenas operações morfológicas. O grau de detalhamento obtido pode ser controlado modificando-se o número de iterações do algoritmo, e o melhor valor é obtido empiricamente.

O algoritmo pode ser resumido como:

Algoritmo 1: Algoritmo de Extração Semi-automática de Tecido Cerebral
--

Data: imagem, $nIteracoes$

Result: mascara

<pre> 1 ajusta contraste; 2 calcula limiar; 3 limiariza; 4 aplica morfologia; 5 apaga artefatos; 6 inicializa contorno ativo; 7 for $nIteracoes$ do 8 executa contorno ativo; 9 end </pre>

3.2.5 Padronização de Intensidade

A falta de padronização de intensidade, inerente às imagens obtidas pela técnica de ressonância magnética, dificulta a atribuição de uma faixa de valores a um determinado tipo de tecido. Isso torna mais difícil a adoção de características de intensidade como fontes de informação na segmentação das imagens. A aplicação de métodos para padronização (ou normalização) das intensidades é recomendada quando se pretende fazer uso dos valores de intensidade dos pixels. Diversos trabalhos da literatura incluem esse tipo de tarefa em seus passos de pré-processamento.

Neste trabalho, o método descrito por Nyúl et al. (NYUL; UDUPA, 1999; NYUL; UDUPA; ZHANG, 2000) é adotado devido à sua simplicidade, rapidez de implementação, e bons resultados relatados na literatura.

3.3 Extração de Características

Essa etapa tem a função de processar as informações contidas na imagem e gerar características que serão dispostas em um vetor e classificadas na etapa seguinte. Como já foi dito anteriormente, o foco deste trabalho está no uso de características de textura, como as descritas no capítulo 2. Porém, na literatura, é comum a adição de características de textura com características de outra natureza, como valores de intensidade ou probabilidade à priori de um atlas anatômico. Os valores de intensidades dos pixels foram adotados nesse trabalho.

3.3.1 Extração de textura

Segundo (CASTELLANO et al., 2004) os parâmetros mais utilizados na análise de texturas em imagens de ressonância magnética do cérebro são do tipo estatístico, baseado em modelo e baseado em processamento de sinais. Nesse trabalho são adotados descritores de textura da mesma natureza. Sendo eles:

- estatísticos: matrizes de co-ocorrência, com os parâmetros de textura originais, descritos em (HARALICK; SHANMUGAM; DINSTEN, 1973; HARALICK, 1979); e matrizes *run-length* como descrito em (CHU; SEHGAL; GREELEAF, 1990; DASARATHY; HOLDER, 1991);
- baseados em modelos: descritores de textura baseados em campos aleatórios de Markov e em fractais;
- baseados em processamento de sinais: descritores de textura extraídos por filtros de Gabor e por wavelets.

Estes descritores são calculados paralelamente para cada tipo de imagem de RM adotado.

3.3.2 Seleção de Características

Como em muitos sistemas que utilizam uma grande quantidade de características para classificação, existe o risco da *Praga da Dimensionalidade*, ou seja, o crescimento exponencial da necessidade de amostras de treino, gerado pela adição de novas características ao problema (DUDA; HART; STORK, 2001). Tal fato aumenta o custo computacional

podendo inviabilizar o algoritmo. O uso de métodos para seleção de características relevantes reduz a dimensionalidade, diminuindo o custo computacional, e em alguns casos, melhorando a precisão da classificação (ZONGKER; JAIN, 1996).

Neste trabalho, foi adotado um algoritmo de seleção de características híbrido (ver capítulo 2), descrito em (PENG; LONG; DING, 2005), que utiliza métodos para filtragem e seleção de características candidatas, e aplica métodos de *wrapper* para obter um subconjunto de características otimizado. A vantagem desse algoritmo é a adoção de um método de *wrapper* (que fornece melhores resultados) sem o custo computacional elevado, pois o conjunto de características é pré-filtrado.

3.4 Segmentação

O vetor de parâmetros de textura proveniente da etapa de extração de características forma um espaço de valores de distribuição desconhecida e de alta dimensionalidade, o que torna necessário um método de classificação robusto, capaz de suportar grandes dimensões e que seja não paramétrico.

3.4.1 Classificação

Seguindo os resultados encontrados na literatura, as Máquinas de Vetor de Suporte (*Support Vector Machines - SVMs*) atendem a tais requisitos, o que motivou sua escolha como método de classificação para este trabalho. Dentre as suas vantagens estão algumas características desejáveis, como (SMOLA et al., 1999):

- boa capacidade de generalização: classificadores gerados por SVMs possuem boa capacidade de generalização, o que significa que esses classificadores evitam excesso de ajuste (*overfitting*, especialização exagerada em um certo conjunto de dados, o classificador "memoriza" a classificação e perde a capacidade de generalizar) e falta de ajuste (*underfitting*, excesso de generalização, o classificador passa a cometer muitos erros, pois realiza uma classificação muito "genérica");
- robustez em grandes dimensões: SVMs são robustas na classificação de elementos com alta dimensionalidade de características;
- convexidade da função objetivo: as SVMs resultam na otimização de uma função quadrática, que possui apenas um mínimo global, o que a torna mais vantajosa que,

por exemplo, redes neurais (cujas funções objetivo podem possuir vários mínimos locais);

- teoria bem definida: a teoria utilizada nas SVMs já é bem estabelecida na matemática.

Antes do uso efetivo do classificador há uma fase treinamento, onde é empregado um conjunto de treino no formato

$$S = (x_1, y_1), (x_2, y_2), \dots, (x_i, y_i)$$

sendo x_i um vetor multidimensional e y_i sua classificação. O papel das SVMs dentro deste trabalho é separar os elementos do hiperespaço de características obtido na etapa de extração de características nas classes **tumor** e **não-tumor**.

3.4.2 Máquinas de Vetor de Suporte

As Máquinas de Vetor de Suporte constituem uma técnica de reconhecimento de padrões baseada na Teoria do Aprendizado Estatístico (TAE) (VAPNIK, 1995), de treinamento supervisionado, cujo objetivo é a maximização da generalização do aprendizado, através da busca pelo equilíbrio certo entre acuidade e capacidade (BURGES, 1998); onde por acuidade entende-se a precisão que o classificador adquire para classificar elementos dentro de um determinado conjunto de treinamento, e por capacidade a habilidade da máquina de ser treinada sem erro, dado qualquer conjunto de treinamento (BURGES, 1998).

O principal objetivo das SVMs é encontrar um hiperplano de classificação otimizado de forma a minimizar a quantidade de erros, tendo em vista tanto os conjuntos de teste como os conjuntos de treinamento. Para tanto, as SVMs se baseiam na minimização do Risco Funcional (ao contrário de outros algoritmos de aprendizado de máquina, como Redes Neurais, que buscam minimizar o Risco Empírico) o que faz com que possuam melhor generalização global. Por Risco Empírico entende-se a porcentagem de classificações incorretas obtidas dentro de um determinado conjunto de treinamento, e por Risco Funcional a probabilidade que o classificador cometa um erro durante a fase de testes. O Risco Funcional quantifica a capacidade de generalização do classificador (LORENA; CARVALHO, 2003). A TAE demonstra matematicamente que a minimização do Risco Funcional está diretamente ligada a (VAPNIK, 1995):

- minimização do Risco Empírico;

- maximização da margem, que leva a classificadores com dimensão Vapnik-Chervonenkis (VC) pequena.

Máquinas de Vetor de Suporte Lineares

Figura 3.4: Separador linear e suas margens

As SVMs são originalmente utilizadas na classificação de problemas com duas classes, sendo os problemas linearmente separáveis o caso mais trivial. Problemas linearmente separáveis são aqueles onde existe um hiperplano separador que classifica corretamente todos os elementos do conjunto (DUDA; HART; STORK, 2001). Na figura 3.4 S é um separador (também conhecido como classificador) linear que pode ser definido pela equação

$$wx + b = 0 \quad (3.1)$$

e $r1$ e $r2$ os planos que delimitam a margem de separação dos elementos do conjunto. $r1$ e $r2$ podem ser descritas respectivamente por $wx + b = -1$ e $wx + b = 1$, portanto os classificadores lineares podem ser caracterizados pela desigualdade 3.2

$$\begin{cases} wx_i + b \geq +1 & \text{se } y_i = 1 \\ wx_i + b \leq -1 & \text{se } y_i = -1 \\ i=1,2,\dots,n \end{cases} \quad (3.2)$$

A tarefa da SVM, no caso linear, é buscar o par (w, b) que gere um classificador capaz de classificar corretamente todos os elementos do conjunto, e que possua a maior margem

Figura 3.5: Problema linearmente separável e seu classificador, obtido por uma SVM

($d^* + d^{**}$ da figura 3.4). A distância entre os planos $r1$ e $r2$ pode ser calculada por

$$d^* + d^{**} = \frac{2}{\|w\|} \quad (3.3)$$

e a distância entre o plano S e um dos planos r é dada por

$$d^* = d^{**} = \frac{1}{\|w\|} \quad (3.4)$$

consequentemente, a minimização de $\|w\|$ leva a uma maximização da margem. Esse problema pode ser reescrito na forma de um problema de otimização com restrições:

Minimizar: $\|w\|^2$

Sob as restrições: $y_i(wx_i + b) - 1 \geq 0$, para $i = 1, \dots, n$

A resolução deste problema de minimização é calculada utilizando-se Programação Quadrática, que é amplamente discutida na literatura. Para tal, é introduzido o uso da função Lagrangiana definida em termos de w e b , originando a seguinte equação:

$$L(w, b, \alpha) = \frac{1}{2}\|w\|^2 - \sum_{i=1}^n \alpha_i (y_i(wx_i + b) - 1) \quad (3.5)$$

onde os α_i são denominados multiplicadores de Lagrange. O problema passa a ser a minimização dessa equação em relação a w e b , e a maximização dos α_i . Com alguma manipulação matemática ((LORENA; CARVALHO, 2003) apresenta os detalhes matemáticos completos), pode-se obter o seguinte problema de otimização:

$$\begin{aligned} \text{Maximizar: } & \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j x_i x_j \\ \text{Sujeito a: } & \begin{cases} \alpha_i \geq 0, & i=1, \dots, n \\ \sum_{i=1}^n \alpha_i y_i = 0 \end{cases} \end{aligned}$$

Esta formulação é chamada dual, e através de sua resolução obtém-se o hiperplano resultante, denominado Hiperplano Ótimo. Os pontos contidos nos planos $r1$ e $r2$ se removidos mudam a largura da margem de separação, e, conseqüentemente, a solução encontrada, são chamados de Vetores de Suporte e são os elementos mais significativos do conjunto (BURGES, 1998) (encontram-se circulados na figura 3.4). Na figura 3.5 tem-se o gráfico de dois conjuntos linearmente separáveis e seu classificador obtido através do treinamento de uma SVM.

Máquinas de Vetor de Suporte de Fronteiras Suaves

Figura 3.6: Problema com fronteiras suaves e classificador, obtido por uma SVM

Em situações práticas, os conjuntos dificilmente possuem separabilidade linear, tanto devido à presença de ruído nas amostras, como devido à natureza do problema que se quer modelar. Para lidar com tal fato, variáveis de relaxamento são adicionadas ao conceito descrito acima, de forma a admitir a ocorrência de erros durante a classificação. Essa técnica também evita que a SVM ajuste o classificador segundo o ruído contido nos dados (LORENA; CARVALHO, 2003). Na figura 3.6, tem-se um exemplo de classificador de fronteiras suaves gerado por uma SVM.

Máquinas de Vetor de Suporte Não-lineares

Figura 3.7: Problema não linearmente separável e classificador

Mesmo as SVMs de fronteiras suaves podem não ser suficientes para resolver problemas mais complexos, como o ilustrado na figura 3.7, onde não é possível dividir os dados por um hiperplano. Para resolver tal problema, utiliza-se uma generalização da SVM linear que permite mapear o conjunto de entrada em um Espaço de Características, de dimensão maior ou igual a do espaço de entrada, onde os elementos de entrada se tornam linearmente separáveis. O mapeamento é feito através do uso de funções reais ($\Phi(\cdot)$) resultando em $\Phi(S)$ (LORENA; CARVALHO, 2003):

$$\Phi(S) = (\Phi(x_1), y_1), (\Phi(x_2), y_2), \dots, (\Phi(x_n), y_n)$$

onde S é um conjunto de treinamento, x_n um elemento de um conjunto e y_n sua classe. Porém, o uso direto das funções $\Phi(\cdot)$ pode ser trabalhoso devido à alta dimensionalidade que o espaço de características pode alcançar. Assim são utilizadas funções de Kernel para substituir o uso direto das funções $\Phi(\cdot)$ (prática conhecida como *Kernel Trick* na literatura). As funções de Kernel calculam o produto escalar $\Phi(x_i) \cdot \Phi(x_j)$ sendo descritas como:

$$K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) \quad (3.6)$$

O uso de funções kernel leva à simplificação dos cálculos e representação de espaços muito abstratos (LORENA; CARVALHO, 2003). Os tipos de kernel mais utilizados são:

- polinomial,
- gaussiano,
- sigmoidal,
- função de base radial (*radial basis function* - *RBF*).

Neste trabalho, o kernel utilizado é o RBF por ser o mais versátil, apresentando os melhores resultados iniciais de classificação.

3.5 Pós-processamento

A etapa de classificação normalmente não é perfeita, uma vez que o classificador pode atribuir erroneamente elementos do conjunto de testes à classe incorreta, gerando pontos ou pequenas regiões conexas na segmentação final. A forma mais simples de tratar tal problema é utilizando-se operações morfológicas como dilatação e erosão (ZHOU et al., 2005), apesar de existirem métodos mais complexos como o uso de filtros de mediana (SCHMIDT, 2005) ou limiarização local seguida de crescimento de região (SHAHMORAD et al., 2007). Por serem rápidas e eficientes, as operações morfológicas são adotadas na etapa de pós-processamento deste trabalho, para refinar a segmentação obtida.

3.6 Conclusão

Neste capítulo, foram apresentados os componentes que fazem parte do sistema aqui proposto, o qual possui quatro etapas básica: pré-processamento, extração de características, segmentação e pós-processamento. Tal concepção foi formulada tendo como base as pesquisas realizadas no estado-da-arte da literatura, buscando reunir diversos métodos de forma a possibilitar a segmentação efetiva dos tumores do encéfalo.

4 Implementação do Sistema para Segmentação de Tumores do Encéfalo

Nos capítulos 2 e 3 foram apresentados os principais conceitos relacionados à segmentação de tumores de encéfalo, tendo como ênfase o cérebro; alguns trabalhos relacionados, e a descrição detalhada de uma proposta de sistema. Neste capítulo, serão apresentados os detalhes da implementação realizada.

Neste trabalho, foram utilizados exames de RM de onze pacientes distintos, portadores de tumores de encéfalo confirmados por análise patológica. Cada exame contém três volumes de imagens: ponderadas em T1, T1 com contraste (T1c) e FLAIR, em formato DICOM. Os casos analisados são: quatro glioblastomas multiformes, dois astrocitomas de grau II, um meningioma, um meduloblastoma, um metacarcinoma, um pnet e um ependimoma. Todos os exames foram realizados em um mesmo equipamento da GE Medical Systems de 1.5T. As segmentações manuais dos tumores, utilizadas como “padrão ouro”, foram efetuadas por dois radiologistas (aqui denominados “médico#1” e “médico#2”) com mais de dez anos de experiência na área, em imagens ponderadas em T1 com contraste.

Todo o desenvolvimento foi realizado utilizando o programa Matlab (que permite rápida prototipagem), com exceção do processo de correção de heterogeneidades de campo, na etapa de pré-processamento, onde se adotou a ferramenta MIPAV (MIPAV..., 2008).

4.1 Pré-processamento

A etapa de pré-processamento foi implementada seguindo a descrição apresentada. Seu desenvolvimento teve especial atenção, pois um pré-processamento inadequado comprometeria os resultados das segmentações finais. Ao final dessa etapa, tem-se dois pro-

Figura 4.1: Máscaras utilizadas no pré-processamento

duetos: as imagens devidamente tratadas, e as máscaras que auxiliam a etapa de Extração de Características. Essas máscaras nada mais são que o resultado da remoção do tecido extra-encefálico e fundo, manualmente tratadas para incorporar as segmentações “padrão ouro”. Tais máscaras são utilizadas durante o cálculo dos parâmetros de textura, de forma a delimitar a região de interesse (no caso apenas a região do encéfalo), e a separar as características calculadas sobre tecidos saudáveis daquelas calculadas sobre os tecidos doentes. É importante notar que a tarefa de incorporação da segmentação manual nessas máscaras também poderia ser facilmente automatizada.

A figura 4.1 mostra algumas das máscaras geradas. A primeira linha contém imagens T1c com as segmentações “padrão ouro” criadas pelo médico (no caso médico #1). A segunda linha contém as máscaras geradas após a remoção do tecido extra-encefálico e fundo, e a terceira linha mostra as máscaras finais, que são aplicadas no processo de Extração de Características (note a região tumoral em cinza).

A figura 4.2 mostra a saída de cada processo da etapa de pré-processamento, para um determinado exame. Na primeira linha, da esquerda para direita estão: a) imagem original, b) imagem após correção de heterogeneidades de campo, c) imagem após suavização de ruído, d) imagem após registro, e) imagem após extração de crânio e f) imagem após normalização de intensidades. Para melhor interpretação dos resultados, na segunda linha foram incluídas as imagens das diferenças absolutas entre o resultado de uma etapa e a etapa anterior.

Figura 4.2: Resultado das sub-etapas do pré-processamento

4.2 Extração de Características

Para a extração de características, uma biblioteca especializada em calcular parâmetros de textura foi implementada, contendo funções capazes de calcular parâmetros para os diversos tipos de textura pesquisados. É possível calcular especificamente 158 tipos

Figura 4.3: Resultado do cálculo de características de MCO de um conjunto de imagens (T1, T1c e FLAIR)

de textura diferentes. Sendo eles:

- parâmetros de matrizes de co-ocorrências:
segundo momento angular, contraste, correlação, variância, momento diferença inverso, somas das médias, soma da variância, entropia, soma da entropia, diferença

Figura 4.4: Resultado do cálculo de características de textura estatísticas, baseadas em modelo e em transformada, de um conjunto de imagens (T1, T1c e FLAIR)

da variância, diferença da entropia (todos os parâmetros em orientações de 0° , 45° , 90° e 135°), totalizando 44 características;

- parâmetros de matrizes *run-length*:
orientações de 0° , 45° , 90° e 135° para SRE, LRE, GLN, RLN, RP, LGRE, HGRE, SRLGE, SRHGE, LRLGE, LRHGE (ver capítulo 2 para siglas), totalizando 44 características;
- parâmetros por wavelets:
wavelets de Daubechies (db4), Coiflets (coif3), Symlets (sym2), Biortogonais (bior5.5). Utiliza-se 2 iterações para cada wavelet, o que faz com que haja seis características de cada tipo adotado (três canais - LH, HH e HL - para cada iteração), totalizando 24 características;
- parâmetro de dimensão fractal (totalizando 1 característica);
- parâmetros de campos aleatórios de Markov:
parâmetros de primeira ordem (2 características mais a variância), segunda ordem (4 características mais a variância), terceira ordem (6 características mais a variância), quarta ordem (10 características mais a variância) e quinta ordem (12 características mais a variância), totalizando 39 características. O algoritmo detalhado para cálculo dessas características pode ser encontrado em (MANJUNATH; CHELLAPPA, 1991);

- parâmetros por filtros de Gabor:

seis canais de filtragem, sendo cada canal definido por: desvio padrão do envelope gaussiano (σ); frequência espacial da senóide em coordenadas polares (F,W), com F a magnitude e W o ângulo; e a fase da senóide (P). Para cada canal foram utilizados respectivamente os seguintes parâmetros: $\sigma = 0,05$, $F = 0,05$, $W = 0$, $P = 0$; $\sigma = 0,05$, $F = 0,05$, $W = 45$, $P = 0$; $\sigma = 0,05$, $F = 0,05$, $W = 90$, $P = 0$; $\sigma = 0,05$, $F = 0,025$, $W = 0$, $P = 0$; $\sigma = 0,05$, $F = 0,025$, $W = 45$, $P = 0$; $\sigma = 0,05$, $F = 0,025$, $W = 90$, $P = 0$.

Todos esses parâmetros de textura são calculados para as imagens T1, T1c e FLAIR, com o auxílio de uma janela móvel de 9x9 pixels centralizada ponto a ponto, e todas as imagens são convertidas para 8 níveis de cinza.

Na figura 4.3, tem-se o exemplo seis parâmetros de textura por matrizes de co-ocorrências, calculados para três tipos de imagem. Na primeira linha tem-se os parâmetros calculados para uma imagem FLAIR, na segunda, para uma imagem T1c, e na terceira, para uma T1. Da esquerda para a direita tem-se: energia, contraste, entropia, homogeneidade, e soma das médias. As máscaras geradas no pré-processamento auxiliam na separação entre características pertencentes a tecidos saudáveis e doentes, que são armazenadas em vetores distintos.

Na figura 4.4 tem-se da esquerda para direita: intensidade dos pixels, segundo momento angular, SRE, wavelet db4, dimensão fractal, primeira ordem do campo aleatório de Markov, um dos canais de Gabor. Na primeira linha tem-se os parâmetros para uma imagem T1, na segunda para T1c e na última para FLAIR.

4.2.1 Seleção de Características

Uma matriz contendo as 477 características (158 características de textura, mais o valor de intensidade, calculados para cada imagem - T1, T1c e FLAIR) para cada ponto da imagem é recebida pelo algoritmo de seleção de características, que as analisa e devolve as vinte características mais relevantes. Tais características são então utilizadas para a segmentação da etapa seguinte. Verificou-se empiricamente que mesmo quando há variação na quantidade de informação (conjuntos de treinamento) apresentada para o algoritmo, há pouca variação na resposta obtida, pois são gerados vetores semelhantes após diferentes execuções. As características selecionadas como ótimas a maior parte do tempo foram: intensidade dos pixels de T1c, LRE em 0° de FLAIR, correlação em 145°

de T1c, LRLGE em 90° de T1c, θ_1 Markov de 5ª ordem de T1c, dimensão fractal de T1c, Gabor em 90° de T1c, LRLGE em 135° de FLAIR, soma das variâncias em 90° de T1c, contraste em 45° de T1c, intensidade dos pixels de FLAIR, LRLGE em 135° de T1c, soma das variâncias em 45° de FLAIR, θ_2 Markov de 5ª ordem de T1c, diferença das variâncias em 0° de T1c, Gabor em 45° de T1c, θ_1 Markov de 1ª ordem de T1, GLN em 0° de T1c, correlação em 45° de FLAIR, e LRE em 0° de T1c. Estas foram as características utilizadas na segmentação.

4.3 Segmentação

Durante a segmentação, uma Máquina de Vetor de Suporte é responsável pela separação dos pixels em duas classes: tumor e não-tumor. A biblioteca de SVM adotada é chamada LIBSVM. Entre suas vantagens está a maturidade do projeto, existência de uma boa documentação, e implementação para Matlab (CHANG; LIN, 2001).

Figura 4.5: Resultado final da etapa de segmentação

Por ser um método de aprendizado supervisionado, a SVM deve passar por uma fase de treinamento antes que possa ser utilizada. Para tanto, a SVM recebe um vetor multidimensional de características, juntamente com um vetor contendo as classes corretas (provenientes das máscaras geradas no pré-processamento) para cada ponto. É importante notar que o vetor deve ser balanceado, ou seja, deve conter a mesma quantidade de pontos das duas classes, para que não haja *bias* no treinamento.

Para a classificação, o procedimento é semelhante. A SVM recebe um vetor de características balanceado, correspondente à imagem que se quer segmentar, dessa vez sem o vetor de classes. O resultado da classificação equivale à segmentação da imagem. Na figura 4.5, tem-se alguns exemplos do resultado da segmentação após a classificação. Na

primeira linha, tem-se as imagens T1c pré-processadas, e na segunda linha tem-se suas respectivas segmentações. Pode-se notar a presença de regiões classificadas incorretamente. Tal problema é tratado durante o pós-processamento.

4.4 Pós-processamento

O pós-processamento aplicado é bastante simples, constituído de operações morfológicas básicas. Para pós-processar a imagem resultante da etapa de segmentação, primeira-

Figura 4.6: Resultado final após a etapa de pós-processamento

mente são filtradas todas as pequenas estruturas, permanecendo apenas a maior estrutura conexa encontrada, em seguida, todos os “buracos” dessa região são preenchidos. À região resultante é aplicada uma erosão utilizando um objeto estruturante quadrado de 3x3 pixels. O objetivo desta operação é o desligamento de pequenas protuberâncias ligadas à região segmentada, mas que não pertençam a esta. O passo final é a realização de uma nova filtragem e preenchimento, semelhante ao primeiro passo descrito.

Na figura 4.6 tem-se os resultados após segmentação e pós-processamento, juntos para permitir uma comparação visual dos resultados. Na primeira linha, tem-se imagens T1c pré-processadas, de cinco exames distintos. Na segunda linha, tem-se o resultado após a segmentação destas, e na terceira linha o resultado da segmentação pós-processada. Pode-se notar uma melhora considerável no resultado obtido.

4.5 Conclusão

Neste capítulo foram apresentados os detalhes da implementação do sistema descrito, com exemplo de imagens geradas em cada etapa. No próximo capítulo serão apresentados os resultados obtidos após os testes.

5 *Resultados Obtidos*

Neste capítulo são apresentados os resultados obtidos utilizando o sistema implementado. Para realização dos testes foram montados onze conjuntos de imagens, numerados de #1 a #11, cada um contendo um exame diferente. Cada conjunto é formado por três “tuplas” (cada tupla é formada por uma imagem T1, uma imagem T1c e uma imagem FLAIR), numeradas de 1 a 3, referentes a três fatias adjacentes provenientes da região tumoral, selecionadas dentre todas as fatias do exame por estarem aproximadamente na região central do tumor. Cada conjunto foi submetido às etapas descritas no capítulo 3. A análise quantitativa dos resultados obtidos ao final do processamento foi realizada comparando-se as regiões delimitadas pelo sistema com as regiões segmentadas manualmente, por dois radiologistas experientes (denominadas padrão ouro).

Os resultados apresentados para cada médico foram obtidos treinando-se a SVM com os padrões ouro gerados por este, e depois comparando-se o resultado da segmentação final com seu respectivo padrão ouro. Ou seja, os testes foram realizados duas vezes. Na primeira vez, a SVM foi treinada com os padrões ouro do médico #1, e a segmentação final comparada com as segmentações manuais realizadas por este. Na segunda vez, o mesmo procedimento foi realizado utilizando as segmentações manuais do médico #2. Os testes foram conduzidos desta forma para evitar problemas no treinamento da SVM, pois as segmentações manuais dos dois médicos não são idênticas, o que introduziria incoerências nos dados de treinamento, caso fossem utilizados juntos, e prejudicariam o processo.

5.1 *Comparação com Resultados da Literatura*

Nas tabelas 5.1, 5.2 e 5.3 tem-se os resultados listados para o médico #1, médico #2 e a média entre os dois. A quantificação dos resultados foi calculada utilizando-se métricas encontradas na literatura, e os resultados comparados com aqueles obtidos por outros autores. Os artigos citados neste capítulo foram selecionados para comparação por apresentarem de forma detalhada e clara as métricas utilizadas e respectivos resultados

obtidos.

Para realização dos testes de segmentação foi adotada a metodologia *leave-one-out*, onde para N conjuntos de dados, $N - 1$ conjuntos são utilizados no treinamento do classificador, e o conjunto restante é usado para realizar o teste. O resultado obtido através desse método foi submetido a quantificações e comparações utilizando os métodos apresentados por três artigos encontrados na literatura.

A primeira comparação foi realizada com o trabalho de (ZHANG; MA; ER, 2004) que descreve uma métrica chamada de Porcentagem de Acerto (PA), a qual é calculada em termos do número de Positivos Verdadeiros (PV) e dos pixels Padrão Ouro (PO). Seja PO o conjunto dos pixels da segmentação padrão ouro, realizada pelos radiologistas, e Ω o conjunto de pixels da segmentação realizada pelo sistema. O conjunto PV pode ser definido como:

$$PV = \{x(i, j) | x \in PO, x \in \Omega\} = PO \cap \Omega$$

onde $x(i, j)$ representa a intensidade do pixel na coordenada (i, j) . A medida de porcentagem PA é definida como:

$$PA = \frac{\#(PV)}{\#(PO)}$$

onde $\#(.)$ indica a cardinalidade do conjunto. A PA fornece a porcentagem de acertos entre a segmentação padrão ouro e a segmentação realizada pelo sistema. A partir da diferença entre PO e Ω , pode-se definir o conjunto de Falsos Positivos (FP):

$$FP = \{x(i, j) | x \notin PO, x \in \Omega\} = \overline{PO} \cap \Omega$$

Analogamente, podemos definir o conjunto de Falsos Negativos (FN):

$$FN = \{x(i, j) | x \in PO, x \notin \Omega\} = PO \cap \overline{\Omega}$$

As comparações seguintes foram realizadas entre os resultados obtidos e os trabalhos de (FLETCHER-HEATH et al., 2001) e (ZHOU et al., 2005), os quais adotam a métrica de Porcentagem de Acerto, e a ela acrescentam a Taxa de Correspondência (TC). Em ambos os trabalhos a PA é definida como:

$$PA = \frac{\#(PV)}{\#(PO)} \cdot 100$$

e a TC como:

$$TC = \frac{\#(PV) - 0,5 \cdot \#(FP)}{\#(PO)}$$

A PA é calculada como a proporção direta entre o número de positivos verdadeiros e o

número de pixels do padrão ouro. O valor ideal para a PA é de 100%. Uma PA igual a zero indica que houve uma completa falha na localização dos pixels de tumor. Quanto mais alto o valor da PA, maior o número de positivos verdadeiros contidos na região segmentada. Já a TC permite discutir a veracidade da localização e tamanho da massa tumoral isolada pelo sistema, em relação à massa identificada no padrão ouro. Seu cálculo é feito de forma a ponderar a importância do número de falsos positivos e falsos negativos no valor final. Um valor de TC próximo de um indica que a segmentação contém um maior número de positivos verdadeiros e um menor número de falsos positivos, enquanto um valor negativo indica que houve uma proporção maior que dois para um entre falsos positivos e positivos verdadeiros. O valor ideal para a TC é um.

Na tabela 5.1, tem-se a quantidade de positivos verdadeiros, falsos positivos, e falsos negativos obtidas comparando-se os resultados alcançados com a segmentação padrão ouro dos respectivos radiologistas, e respectivas médias. Na tabela 5.3, tem-se as porcentagens de acerto ($\times 100$) e as taxas de correspondência calculadas para cada um dos padrões ouro, e sua média, e a tabela 5.2 apresenta as porcentagens de PV, FP e FN em relação ao padrão ouro. Essa tabela é útil para dar uma melhor ideia da proporção que cada medida toma dentro dos casos testados.

No trabalho de (ZHANG; MA; ER, 2004), cujos resultados são apresentados na tabela 5.4, os autores obtiveram uma PA média de 90%, o que foi considerado um resultado satisfatório e promissor. No trabalho aqui apresentado a PA média obtida foi de 94%, resultado quantitativamente superior ao apresentado pelos autores, o que indica que esse sistema foi capaz de incluir mais pixels da região de tumor na segmentação.

Entretanto em (ZHANG; MA; ER, 2004) a ocorrência média de falsos positivos foi de 902,63, e o número de positivos verdadeiros foi de 3662, o que mostra que o método dos autores não realizou uma superestimação exagerada da região tumoral; ao contrário do que ocorreu neste trabalho, onde a média de falsos positivos (2910,55) ultrapassou a de positivos verdadeiros (2037,68).

No trabalho de (FLETCHER-HEATH et al., 2001), os autores tecem suas considerações sobre os resultados obtidos tendo como base o pior e o melhor resultado. No pior caso o número de positivos verdadeiros é 204,75, de falsos positivos 35,57, TC média de 0,42 e PA média de 58,5%. Já no melhor caso, o número médio de positivos verdadeiros é de 550, de falso positivos 21,36, TC média de 0,75 e PA média de 85,71%. No trabalho aqui apresentado o melhor caso, que ocorreu para o paciente #1, apresentou um número médio de positivos verdadeiros de 2353,2, uma média de 852,83 falsos positivos, uma PA média

de 99,21% e TC média de 0,81. Assim, o melhor caso deste trabalho apresenta resultados superiores ao melhor caso da referência citada. Porém, o pior caso, que ocorreu para o paciente #11, apresenta resultados bastante inferiores ao pior caso citado, apresentando uma média de positivos verdadeiros de 1707,8, média de falsos positivos de 9849,3, PA média de 74,19% e TC média de -1,5. O valor negativo da TC média indica a existência de uma quantidade excessiva de falsos positivos, em razão da superestimação da massa tumoral.

No trabalho de (ZHOU et al., 2005), cujos resultados são apresentados na tabela 5.5, os autores discutem seus resultados quanto ao valor mínimo e máximo de PA e TC. Sendo a menor PA 6,4% e a maior 90,8%, e a maior média obtida 88,6%. Já a TC mínima é de 0,65, a máxima 0,87, e a maior média 1,38. No trabalho aqui apresentado a menor PA média é 74,19%, e a maior 99,88%, enquanto que a menor TC média é -1,95 e a maior 0,81.

Para ilustrar melhor os resultados, e facilitar a interpretação das tabelas, as figuras 5.1, 5.2, 5.3, 5.4 e 5.5 trazem alguns dos melhores e piores resultados obtidos pelo sistema. Para todas as figuras, os quadros a, b e c trazem as imagens T1, T1c e FLAIR utilizadas nos testes. Os quadros d e f trazem as máscaras que incorporam as segmentações padrão ouro (em cinza escuro) respectivamente do médico #1 e médico #2, e os quadros e g trazem os resultados das segmentações finais obtidas, respectivamente, para treinamento com padrão ouro do médico #1, e padrão ouro do médico #2. Os quadros h e i trazem a área da região segmentada sobreposta pelos padrões ouro dos médicos #1 e #2 respectivamente. Nesses dois quadros, as regiões em cinza escuro correspondem à intersecção do padrão ouro com a segmentação do sistema (positivos verdadeiros), a região em cinza médio corresponde ao restante do encéfalo, em branco está a região segmentada pelo sistema que não sobrepõe o padrão ouro (falsos positivos) e em preto a região segmentada pelo médico não contemplada pela segmentação do sistema (falsos negativos). O quadro j traz os padrões ouro dos médicos #1 e #2 sobrepostos. Nesse quadro a região cinza escuro corresponde à intersecção entre as duas segmentações.

A figura 5.1 corresponde aos resultados obtidos para a tupla 1 do paciente #1, e é considerado o melhor resultado do sistema. Nela, as PAs foram altas para ambos os médicos, sendo a PA média de 99,7%. As TCs desse caso também foram boas para ambos os médicos, sendo a média 0,86. Não houve superestimação da região tumoral nem quantidade significativa de falsos negativos. Já na figura 5.3, os resultados são apenas razoáveis, sendo melhores para o médico #1 que apresenta uma PA de 99,31%, contra os

66,39% do médico #2. Porém, em ambos os casos as TCs não são muito altas, tendo uma média de 0,59%.

A figura 5.2 corresponde aos resultados da tupla 1 do paciente #5, que é considerado um caso ruim para o sistema, pois, apesar de apresentar uma PA alta para ambos os médicos (100%). Houve superestimação exagerada da região tumoral. A PA máxima indica que toda a área tumoral foi contemplada pela segmentação do sistema, mas a TC negativa e de valor em módulo elevado indica que a área delimitada foi muito maior que a região “padrão ouro”. É interessante notar como a região segmentada pelo sistema é semelhante à região de edema apresentada na imagem FLAIR. Isso pode ser um indicativo de que o sistema considerou os pixels de edema como tumor.

As figuras 5.4 e 5.5 correspondem aos resultados das tuplas #2 e #3 do paciente #11, respectivamente, e são consideradas os piores casos do sistema, sendo 5.5 o pior deles. Pode-se notar nesses dois casos que o sistema foi incapaz de delimitar com alguma precisão a região tumoral. É importante notar que o exame desse paciente apresenta algumas diferenças técnicas (ver anexo A) que podem ter contribuído para uma segmentação ruim, sendo sua resolução menor que a dos demais exames, e a quantidade de ruído presente nas imagens maior. Esse também é o único caso de tumor não realçável pela presença de contraste, fato que também pode contribuir para maior dificuldade na segmentação, já que a SVM é treinada no regime *leave-one-out*. Por apresentar diversas diferenças técnicas, pode ser metodologicamente interessante excluir esse exame dos resultados finais, o que mudaria os valores das médias obtidas. Sem o caso do paciente #11, os resultados obtidos seriam uma PA média de 95,98% e uma TC média de 0,11; haveria uma média de 2003,95 positivos verdadeiros, 2164,17 falsos positivos, e 70,98 falsos negativos.

5.2 Conclusão

Os resultados obtidos apresentam-se satisfatórios, levando à conclusão de que a formulação de um sistema para segmentação de tumores de cérebro descrita nesse trabalho tem potencial para tratar o problema considerado.

		médico #1			médico #2			média		
paciente	fatia	#PV	#FP	#FN	#PV	#FP	#FN	#PV	#FP	#FN
#1	1	2123	601	9	2329	643	4	2226	622	6,5
	2	2256	1002	3	2495	1112	3	2375,5	1057	3
	3	2308	803	54	2608	956	41	2458	879,5	47,5
#2	1	1292	415	602	1571	445	575	1431,5	430	588,5
	2	2292	664	49	2501	543	128	2396,5	603,5	88,5
	3	2105	697	3	2251	605	3	2178	651	3
#3	1	411	1030	80	607	986	41	509	1008	60,5
	2	738	1588	69	929	2090	15	833,5	1839	42
	3	851	630	18	947	558	18	899	594	18
#4	1	2463	5590	0	2757	12217	0	2610	8903,5	0
	2	2188	9223	0	2905	11342	14	2546,5	10282,5	7
	3	1472	9700	3	2231	12613	0	1851,5	11156,5	1,5
#5	1	189	2598	0	311	2605	0	250	2601,5	0
	2	380	1097	0	451	1120	0	415,5	1108,5	0
	3	248	1152	5	362	1240	8	305	1196	6,5
#6	1	2544	1450	1	2794	1559	26	2669	1504,5	13,5
	2	3054	1898	7	3391	1915	22	3222,5	1906,5	14,5
	3	3128	1714	0	3484	1745	4	3306	1729,5	2
#7	1	3781	2752	9	7611	4235	134	5696	3493,5	71,5
	2	2174	1948	15	4394	436	2224	3284	1192	1119,5
	3	1722	1176	212	3211	1112	980	2466,5	1144	596
#8	1	2200	566	14	2347	594	28	2273,5	580	21
	2	2388	1171	2	2533	1465	0	2460,5	1318	1
	3	2158	998	0	2458	878	5	2308	938	2,5
#9	1	2420	795	129	2846	466	366	2633	630,5	247,5
	2	2263	507	210	2694	186	770	2478,5	346,5	490
	3	1796	472	25	1874	545	0	1835	508,5	12,5
#10	1	866	3291	15	451	3586	7	658,5	3438,5	11
	2	1575	2481	34	1487	2910	0	1531	2695,5	17
	3	2037	2028	9	1990	2256	0	2013,5	2142	4,5
#11	1	1910	4685	612	2685	12001	3	2297,5	8343	307,5
	2	1919	13481	14	2150	15498	20	2034,5	14489,5	17
	3	9	1256	1256	1572	12175	658	790,5	6715,5	957
média total								2037,68	2910,55	144,79

Tabela 5.1: Quantidade de positivos verdadeiros (PV), falsos positivos (FP), e falsos negativos (FN) em relação ao padrão ouro dos dois radiologistas e respectivas médias

		médico #1				médico #2				média	
paciente	fatia	#PO	PA(%)	$\frac{\#FP}{\#PO}(\%)$	$\frac{\#FN}{\#PO}(\%)$	#PO	PA(%)	$\frac{\#FP}{\#PO}(\%)$	$\frac{\#FN}{\#PO}(\%)$	$\frac{\#FP}{\#PO}(\%)$	$\frac{\#FN}{\#PO}(\%)$
#1	1	2132	99,58	28,19	0,42	2333	99,83	27,56	0,17	27,88	0,3
	2	2259	99,87	44,36	0,13	2498	99,88	44,52	0,12	44,44	0,13
	3	2362	97,71	34	2,29	2649	98,45	36,09	1,55	35,04	1,92
#2	1	1894	68,22	21,91	31,79	2146	73,21	20,74	26,79	21,32	29,29
	2	2341	97,91	28,36	2,09	2629	95,13	20,65	4,87	24,51	3,48
	3	2108	99,86	33,07	0,14	2254	99,87	26,84	0,13	29,95	0,14
#3	1	491	83,71	209,78	16,29	648	93,67	152,16	6,33	180,97	11,31
	2	807	91,45	196,78	8,55	944	98,41	221,4	1,59	209,09	5,07
	3	869	97,93	72,5	2,07	965	98,14	57,82	1,87	65,16	1,97
#4	1	2463	100	226,96	0	2757	100	443,13	0	335,04	0
	2	2188	100	421,53	0	2919	99,52	388,56	0,48	405,04	0,24
	3	1475	99,8	657,63	0,2	2231	100	565,35	0	611,49	0,1
#5	1	189	100	1374,6	0	311	100	837,62	0	1106,11	0
	2	380	100	288,68	0	451	100	248,34	0	268,51	0
	3	253	98,02	455,34	1,98	370	97,84	335,14	2,16	395,24	2,07
#6	1	2545	99,96	56,97	0,04	2820	99,08	55,28	0,92	56,13	0,48
	2	3061	99,77	62,01	0,23	3413	99,36	56,11	0,65	59,06	0,44
	3	3128	100	54,8	0	3488	99,89	50,03	0,12	52,41	0,06
#7	1	3790	99,76	72,61	0,24	7745	98,27	54,68	1,73	63,65	0,98
	2	2189	99,32	88,99	0,69	6618	66,4	6,59	33,61	47,79	17,15
	3	1934	89,04	60,81	10,96	4191	76,62	26,53	23,38	43,67	17,17
#8	1	2214	99,37	25,57	0,63	2375	98,82	25,01	1,18	25,29	0,91
	2	2390	99,92	49	0,08	2533	100	57,84	0	53,42	0,04
	3	2158	100	46,25	0	2463	99,8	35,65	0,2	40,95	0,1
#9	1	2549	94,94	31,19	5,06	3212	88,61	14,51	11,4	22,85	8,23
	2	2473	91,51	20,5	8,49	3464	77,77	5,37	22,23	12,94	15,36
	3	1821	98,63	25,92	1,37	1874	100	29,08	0	27,5	0,69
#10	1	881	98,3	373,55	1,7	458	98,47	782,97	1,53	578,26	1,62
	2	1609	97,89	154,2	2,11	1487	100	195,7	0	174,95	1,06
	3	2046	99,56	99,12	0,44	1990	100	113,37	0	106,24	0,22
#11	1	2522	75,73	185,77	24,27	2688	99,89	446,47	0,11	316,12	12,19
	2	1933	99,28	697,41	0,72	2170	99,08	714,19	0,92	705,8	0,82
	3	1265	0,71	111,07	99,29	2230	70,49	545,96	29,51	328,52	64,4

Tabela 5.2: Proporção entre PVs, FPs, FNs e o padrão ouro

		médico #1		médico #2		média	
paciente	fatia	PA(%)	TC	PA(%)	TC	PA(%)	TC
#1	1	99,58	0,86	99,83	0,86	99,70	0,86
	2	99,87	0,78	99,88	0,78	99,87	0,78
	3	97,71	0,81	98,45	0,81	98,08	0,81
#2	1	68,22	0,58	73,21	0,63	70,71	0,60
	2	97,91	0,84	95,13	0,85	96,52	0,84
	3	99,86	0,83	99,87	0,86	99,86	0,85
#3	1	83,71	-0,22	93,67	0,18	88,69	-0,02
	2	91,45	-0,07	98,41	-0,12	94,93	-0,09
	3	97,93	0,62	98,13	0,69	98,03	0,65
#4	1	100,00	-0,13	100,00	-1,22	100,00	-0,68
	2	100,00	-1,11	99,52	-0,95	99,76	-1,03
	3	99,80	-2,99	100,00	-1,83	99,90	-2,06
#5	1	100,00	-5,87	100,00	-3,19	100,00	-4,53
	2	100,00	-0,44	100,00	-0,24	100,00	-0,34
	3	98,02	-1,30	97,84	-0,70	97,93	-1,00
#6	1	99,96	0,71	99,08	0,71	99,52	0,71
	2	99,77	0,69	99,36	0,71	99,56	0,70
	3	100,00	0,73	99,89	0,75	99,94	0,74
#7	1	99,76	0,63	98,27	0,71	99,02	0,67
	2	99,31	0,55	66,39	0,63	82,85	0,59
	3	89,04	0,59	76,62	0,63	82,83	0,61
#8	1	99,37	0,87	98,82	0,86	99,09	0,86
	2	99,92	0,75	100,00	0,71	99,96	0,73
	3	100,00	0,77	99,80	0,82	99,90	0,79
#9	1	94,94	0,79	88,61	0,81	91,77	0,80
	2	91,51	0,81	77,77	0,75	84,64	0,78
	3	98,63	0,86	100,00	0,85	99,31	0,86
#10	1	98,3	-0,88	98,47	-2,93	98,38	-1,91
	2	97,89	0,21	100,00	0,02	98,94	0,11
	3	99,56	0,50	100,00	0,43	99,78	0,47
#11	1	75,73	-0,17	99,89	-1,23	87,81	-0,70
	2	99,28	-2,49	99,08	-2,58	99,18	-2,54
	3	0,71	-0,55	70,49	-2,02	35,60	-1,29
média total						94,00	-0,04
média total (sem #11)						95,98	0,11

Tabela 5.3: PAs e TCs obtidas comparando-se o padrão ouro dos dois radiologistas, e PAs e TCs médias

No.	#PV	#FP	#FN	#PO	PA (%)
1	4192	74	522	4714	89
2	3465	302	273	3738	93
3	3696	1326	348	4044	91
4	2899	445	189	3088	94
5	1715	909	109	1824	94
6	1176	709	111	1287	91
7	1113	497	135	1248	88
8	5336	2244	465	5801	92
9	5565	1242	975	6540	86
10	4568	1553	739	5307	86
11	6597	628	1060	7657	86
média total	3665,6	902,63			0,90

Tabela 5.4: Resultados apresentados em (ZHANG; MA; ER, 2004) (modificado)

	PA(%)	TC
mínimo	67,4	0,65
máximo	90,8	0,87
média	83,5	0,78
desvio padrão	5,1	0,06

Tabela 5.5: Resultados apresentados em (ZHOU et al., 2005) (modificado)

Figura 5.1: Resultados do processamento da tupla #1 do paciente #1

Figura 5.2: Resultados do processamento da tupla #1 do paciente #5

Figura 5.3: Resultados do processamento da tupla #2 do paciente #7

Figura 5.4: Resultados do processamento da tupla #2 do paciente #11

Figura 5.5: Resultados do processamento da fatia #3 do paciente #11

6 *Conclusão*

6.1 **Considerações Finais**

Este trabalho teve como objetivo conceber, implementar e avaliar um sistema para segmentar de tumores do encéfalo, com ênfase em tumores de cérebro, em imagens por ressonância magnética, tendo como base características de textura. Para tanto propõe uma formulação de sistema composta de etapas e processos, capaz de lidar com a complexidade inerente a esse tipo de imagem.

A maior dificuldade encontrada durante este trabalho foi a falta de bases de dados de exames de RM que possuíssem segmentação padrão dos tumores, e que pudessem ser utilizados como “padrão ouro” para a delimitação da região tumoral (tarefa importante durante a extração de características) e para a comparação entre os resultados de segmentação obtidos e a região de tumor “verdadeira”. A verificação dos resultados aqui obtidos foi feita adotando-se como “padrão ouro” as segmentações manuais realizadas por dois radiologistas experientes, e comparando-os com três trabalhos da literatura, realizados com outros dados, mas que foram selecionados por apresentarem de forma detalhada e clara a métrica utilizada na apresentação de seus resultados. É importante manter em mente que as comparações realizadas não são completamente “justas”, pois os conjuntos de dados e segmentações adotados nos trabalhos citados não estão publicamente disponíveis, tornando impossível a realização de uma comparação com o mesmo conjunto de dados. Mesmo assim, a comparação entre os resultados aqui obtidos e os apresentados na literatura é uma tarefa importante, pois permite avaliar o potencial da proposta exposta em lidar com o problema considerado.

Os resultados apresentaram-se satisfatórios, atingindo uma média de 94% de porcentagem de acerto após o pós-processamento, para o conjunto de dados utilizado para os testes. É importante notar que os resultados da segmentação foram obtidos automaticamente, sem que houvesse necessidade de interação com o usuário para delimitação de uma região inicial de tumor, ou mesmo para uma segmentação parcial prévia. Após o

treinamento do classificador, o sistema é capaz de localizar sozinho a região de tumor. No capítulo anterior foi detectada ocorrência excessiva de falsos positivos, indicando uma superestimação da massa tumoral, o que aponta a necessidade de mais ajustes nos parâmetros do classificador. Porém, com os dados disponíveis é impossível dizer se todas as áreas consideradas como falsos positivos constituem erro do sistema, ou se este realmente detectou tecido tumoral não percebido por inspeção visual dos radiologistas, dada a natureza infiltrativa de muitos tumores do encéfalo. Para esclarecer essa questão seria necessário dispor de um exame de patologia detalhado de todo o tecido.

6.2 Contribuições

Uma das principais contribuições deste trabalho foi reunir e implementar métodos dispersos na literatura, voltados para o tratamento de diferentes problemas em imagens por RM do encéfalo, e diferentes métodos de análise de textura, em um sistema capaz de localizar e segmentar tumores do encéfalo de forma automática. Esse sistema foi capaz de segmentar os tumores utilizando informações de textura variadas, provenientes de métodos estatísticos, baseados em modelos e baseados em processamento de sinais. Os trabalhos encontrados na literatura tendem a manter o foco em um determinado tipo de textura, como texturas fractais, ou texturas extraídas por wavelet.

Outra contribuição deste trabalho foi a publicação do artigo intitulado “Aplicação de Análise de Texturas na Segmentação de Tumores de Cérebro em Imagens por Ressonância Magnética” (ALEGRO; LOPES, 2008), apresentado no XI Congresso Brasileiro de Informática em Saúde.

Este trabalho também originou uma biblioteca em Matlab, capaz de calcular 158 parâmetros de textura diferentes, descritos no capítulo 2. e o protótipo do *software* de segmentação de tumores, que implementa todas as etapas descritas no capítulo 3.

6.3 Trabalhos Futuros

Seria interessante que o trabalho aqui desenvolvido fosse estendido através da adoção de novos tipos de RM, mais modernos e capazes de detectar informações diferentes das contempladas por T1, T1c e FLAIR; como, por exemplo, imagens de RM de Tensor de Difusão, adicionando essas imagens como novos “canais” de informação ao sistema. Seria interessante também a ampliação do conjunto de treinamento e teste de forma que

houvessem pelo menos dois casos diferentes de cada tipo de tumor, pois acredita-se que o fato de haver muitos tumores que não possuem mais de um caso dentro do conjunto tenha contribuído para a piora no treinamento da SVM e, conseqüentemente, na qualidade final da segmentação.

Quanto à implementação, seria desejável que a biblioteca de texturas e o protótipo desenvolvido em Matlab fossem portados para uma linguagem que permitisse maior otimização e melhores tempos de execução. O uso de Matlab foi motivado por ser um ambiente que permite rápida prototipagem, porém não possui boa eficiência computacional, principalmente para processar *loops*. A implementação em outra linguagem facilitaria a transformação do protótipo em um produto.

Por fim, a implementação do sistema proposto em uma linguagem mais otimizada diminuiria os tempos de execução necessários para o fim de todo o processamento e facilitaria a busca por parâmetros mais eficazes para a inicialização da SVM, e assim provavelmente produziria melhores resultados de segmentação.

Seria útil também, a realização de testes com novos *datasets*, contendo segmentações de mais médicos diferentes, o que possibilitaria a obtenção de melhores avaliações do sistema; e inclusão do uso de dados registrados pixel a pixel com imagens de exames de patologia, o que possibilitaria uma validação real da região segmentada.

APÊNDICE A -- Informações sobre os Exames Utilizados

Nas tabelas a seguir encontram-se informações sobre os exames utilizados neste trabalho. Os tipos de tumor listados são resultado da identificação por exame patológico do tecido, e todos os exames foram realizados num mesmo equipamento GE Medical Systems de 1,5T. A tabela A.2 trás alguns detalhes técnicos como resolução das imagens dos exames, largura das fatias, espaço entre as fatias, e espaçamento entre os pixels.

Paciente	Sexo	Tipo de Tumor	Idade (anos)	Data do Exame
#1	Feminino	Meningioma	36	13/03/2006
#2	Feminino	Glioblastoma Multiforme	64	24/03/2006
#3	Feminino	Meduloblastoma	26	18/04/2006
#4	Masculino	Glioblastoma Multiforme	63	27/04/2006
#5	Feminino	Metacarcinoma	73	28/04/2006
#6	Masculino	Pnet	03	12/09/2006
#7	Masculino	Astrocitoma Grau II	79	21/09/2006
#8	Masculino	Glioblastoma Multiforme	63	22/09/2006
#9	Masculino	Glioblastoma Multiforme	56	03/10/2006
#10	Feminino	Ependimoma	17	17/10/2006
#11	Masculino	Astrocitoma Grau II	52	29/08/2002

Tabela A.1: Informações adicionais sobre os exames utilizados no trabalho

Paciente	Resolução	Largura	Espaço entre Fatias	Espaçamento
#1	512x512	5mm	6,5mm	0,47x0,47
#2	512x512	5mm	6,5mm	0,47x0,47
#3	512x512	5mm	6,5mm	0,47x0,47
#4	512x512	5mm	6,5mm	0,47x0,47
#5	512x512	5mm	6,5mm	0,47x0,47
#6	512x512	5mm	7,0mm	0,47x0,47
#7	512x512	5mm	6,5mm	0,47x0,47
#8	512x512	5mm	6,5mm	0,47x0,47
#9	512x512	5mm	7,5mm	0,47x0,47
#10	512x512	5mm	6,5mm	0,47x0,47
#11	256x256	5mm	7,0mm	0,94x0,94

Tabela A.2: Informações técnicas dos exames utilizados no trabalho

APÊNDICE B -- Artefatos em Imagens de por Ressonância Magnética

Os principais artefatos presentes em imagens de RM (ANDRADE et al., 2002; HORNAK, 1996; SCHMIDT, 2005) são:

Ruído

Se apresenta como um efeito granulado por toda a imagem. Pode ser causado por interferência de radiofrequências oriundas de fontes externas, oriundas do equipamento de ressonância ou oriundas do próprio corpo do paciente.

Heterogeneidade de intensidade

Se apresenta como uma variação de baixa frequência na intensidade dos sinais dentro do volume imageado. Sua principal causa é a heterogeneidade inerente ao magneto do equipamento.

Suscetibilidade magnética

Se mostra como uma área de hipo-intensidade do sinal envolvida por um halo hiper-intenso. É causado por tecido que tem capacidade de adquirir magnetização própria e, geralmente, aparece na presença de ar, metal, cálcio ou agente de contraste concentrado.

Movimento na imagem

Aparece como borrões ou fantasmas nas imagens. É causado por movimentos voluntários ou involuntários do paciente.

Deslocamento químico

Apresenta-se com linhas hiper ou hipo-intensas em volta dos órgãos imageados. É causado

por diferenças nas frequências de ressonância da água e da gordura e/ou pela soma de componentes espectrais dentro de um voxel.

Volume parcial

Se apresenta como perda de resolução da imagem obtida. Sua principal causa é a utilização de voxel de volume grande, o que faz com que a intensidade do voxel represente a combinação das intensidades das estruturas ali contidas.

Dobra da imagem

A imagem gerada aparece “dobrada” nas extremidades da matriz. É causada pela escolha de um campo de visão menor que o objeto imageado.

Anéis de Gibbs

Apresentam-se como linhas paralelas às bordas com alto contraste. São causados pela digitalização incompleta do sinal ecoado pelos tecidos.

Variação de intensidade entre fatias

Se apresenta como a variação de intensidade rápida entre fatias adjacentes dentro de um mesmo volume. Causada geralmente por correntes não uniformes nas bobinas de gradiente.

Falta de padronização de intensidade

Cortes de uma mesma região apresentam intensidades médias diferentes. Tal artefato é causado por discrepâncias nos protocolos de aquisição utilizados e/ou diferenças na construção do hardware dos equipamentos.

Referências Bibliográficas

- ALEGRO, M. C.; LOPES, R. D. Aplicação de análise de texturas na segmentação de tumores de cérebro em imagens por ressonância magnética. *XI Congresso Brasileiro de Informática em Saúde*, dez. 2008.
- ALI-OSMAN, F. *Brain Tumors*. [S.l.]: Humana Press, 2005.
- ANDRADE, G. et al. Artefatos em ressonância magnética do abdome: Ensaio iconográfico. *Radiologia Brasileira*, v. 35, n. 6, p. 371–376, 2002.
- ARIVAZHAGAN, S.; GANESAN, L. Texture classification using wavelet transform. *Pattern Recognition Letters*, n. 24, p. 1513–1521, 2003.
- AYRES, F. *Segmentação e Estimação da Composição Histológica da Massa Tumoral em Imagens de CT de Neuroblastomas*. Dissertação (Mestrado) — EPUSP, 2001.
- BACKES, A. R. et al. Análise de complexidade de texturas em imagens urbanas utilizando dimensão fractal. *IX Brazilian Symposium on GeoInformatics*, p. 215–220, 2007.
- BARNESLEY, M. *Fractals Everywhere*. [S.l.]: Academic Press, 1988.
- BEHIN, A. et al. Primary brain tumor in adults. *The Lancet*, v. 361, jan. 2003.
- BEZDEK, J. C.; HALL, L. O.; CLARKE, L. P. Review of mr image segmentation techniques using pattern recognition. *Medical Physics*, v. 4, n. 20, p. 1033–1048, 1993.
- BOING, A. F.; VARGAS, S. A. L.; BOING, A. C. A carga das neoplasias no brasil: Mortalidade e morbidade hospitalar entre 2002-2004. *Revista da Associação Médica Brasileira*, v. 53, n. 4, p. 317–322, 2007.
- BRAINWEB. *Brainweb: Simulated Brain Database*. 1997.
[Http://www.bic.mni.mcgill.ca/brainweb/](http://www.bic.mni.mcgill.ca/brainweb/).
- BRUMMER, M. E. et al. Automatic detection of brain contours in mri data sets. *IEEE Transactions on Medical Imaging*, v. 12, n. 2, jun. 1993.
- BURGES, C. J. C. A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, n. 2, p. 121–167, 1998.
- CAI, H. et al. Probabilistic segmentation of brain tumors based on multi-modality magnetic resonance images. *4th IEEE International Symposium on Biomedical Imaging*, p. 600–603, 2007.
- CAMPBELL, F. W.; ROBSON, J. G. Application of fourier analysis to the visibility of gratings. *Journal of Physiology*, n. 197, p. 551–566, 1968.

- CASTELLANO, G. et al. Texture analysis of medical images. *Clinical Radiology*, n. 59, p. 1061–1069, 2004.
- CHAN, T. F.; VESE, L. A. Active contours without edges. *IEEE Transactions on Image Processing*, v. 10, n. 2, fev. 2001.
- CHANG, C. C.; LIN, C. J. *LIBSVM: a library for support vector machines*. [S.l.], 2001. [Http://www.csie.ntu.edu.tw/~cjlin/libsvm](http://www.csie.ntu.edu.tw/~cjlin/libsvm) (acesso em 04/03/2009).
- CHU, A.; SEHGAL, C. M.; GREELEAF, J. F. Use of gray value distribution of run length for texture analysis. *Pattern Recognition Letters*, v. 11, p. 412–420, 1990.
- CLARKE, L. P.; et al. Mri measurement of brain tumor response: Comparison of visual metric and automatic segmentation. *Magnetic Resonance Imaging*, v. 16, 1998.
- CLAUSI, D. A.; YUE, B. Comparing cooccurrence probabilities and markov random fields for texture analysis of sar sea ice imagery. *IEEE Transactions on Geoscience and Remote Sensing*, v. 42, n. 1, p. 215–227, jan. 2004.
- COSTA, E. et al. *Tecnologia dos Equipamentos de Imagens*. 2007. Observatório de Radiologia Digital.
- CROSS, G. R.; JAIN, A. K. Markov random field texture models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 5, n. 1, p. 25–39, jan. 1983.
- DASARATHY, B. V.; HOLDER, E. B. Image characterizations based on joint gray level-run length distributions. *Pattern Recognition Letters*, v. 12, 1991.
- DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern Classification*. 2nd. ed. [S.l.]: Wiley-Interscience, 2001.
- DUNKAN, J. S.; AYACHE, M. Medical image analysis: Progress over two decades and the challenges ahead. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 22, n. 1, 2000.
- FARIA, R. R. A. *APLICAÇÃO DE WAVELETS NA ANÁLISE DE GESTOS MUSICAIS EM TIMBRES DE INSTRUMENTOS ACÚSTICOS TRADICIONAIS*. Dissertação (Mestrado) — Escola Politécnica da Universidade de São Paulo, 1997.
- FLETCHER-HEATH, L. M. et al. Automatic segmentation of non-enhancing brain tumors in magnetic resonance images. *Artificial Intelligence in Medicine*, n. 21, p. 43–63, 2001.
- FLEURY, G. C. *Uso de Texturas para o Acompanhamento da Evolução do Tratamento de Úlceras Dermatológicas*. Dissertação (Mestrado) — Escola de Engenharia de São Carlos, 2001.
- FREEBOROUGH, P. A.; FOX, N. C. Mr image texture analysis applied to the diagnosis and tracking of alzheimer's disease. *IEEE Transactions on Medical Imaging*, v. 17, n. 3, jun. 1998.
- FRICOUT, G. et al. Automatic on-line inspection of non-smooth surface. *Wear*, v. 264, p. 416–421, 2008.

- GALANIS, E. et al. Clinical outcome of gliosarcoma compared with glioblastoma multiforme. *J. Neurosurg.*, v. 89, set. 1998.
- GARCÍA, C.; MORENO, J. A. Kernel based method for segmentation and modeling of magnetic resonance images. *IBERAMIA*, 2004.
- GERIG, G. et al. Nonlinear anisotropic filtering of mri data. *IEEE Transactions on Medical Imaging*, v. 11, n. 2, jun. 1992.
- GIBBS, P. et al. Tumor volume determination from mr images by morphological segmentation. *Physics in Medicine and Biology*, 1996.
- GONZALEZ, R. C.; WOODS, R. E. *Processamento de Imagens Digitais*. [S.l.]: Edgard Blucher, 2000.
- GONZALEZ, R. C.; WOODS, R. E.; EDDINGS, S. L. *Digital Image Processing Using MatLab*. [S.l.]: Prentice Hall, 2004.
- GRAPS, A. An introduction to wavelets. *IEEE Computational Science & Engineering*, p. 50–61, 1995.
- GRIGORESCU, S. E.; PETKOV, N.; KRUIZINGA, P. Comparison of texture features based on gabor filters. *IEEE Transactions on Image Processing*, v. 11, n. 10, out. 2002.
- GUYON, I.; ELISSEEFF, A. An introduction to variable and feature selection. *Journal of Machine Learning Research*, v. 3, p. 1157–1182, 2003.
- HARALICK, R. M. Statistical and structural approaches to texture. *Proceeding of the IEEE*, maio 1979.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 1973.
- HERLIDOU-MÊME, S. et al. Mri texture analysis on texture test objects, normal brain and intracranial tumors. *Magnetic Resonance Imaging*, n. 21, p. 989–993, 2003.
- HERLIDOU, S. et al. Comparison of automated and visual texture analysis in mri: Characterization of normal and diseased skeletal muscle. *Magnetic Resonance Imaging*, v. 17, n. 9, p. 1393–1397, 1999.
- HORNAK, J. P. *The Basics of MRI*. 1996. [Http://www.cis.rit.edu/htbooks/mri/](http://www.cis.rit.edu/htbooks/mri/). (acesso em 04/03/2009).
- HOROWITZ, A. L. *MRI Physics for Physicians*. [S.l.]: Springer-Verlag, 1989.
- IFTEKHARUDDIN, K. M.; JIA, W.; MARSH, R. Fractal analysis of tumor in brain mr images. *Machine Vision and Applications*, p. 352–362, 2003.
- IFTEKHARUDDIN, K. M.; ZHENG, J.; ISLAM, M. A. Brain tumor detection in mri: Technique and statistical validation. *IEEE ACSSC 06*, 2006.
- INCA. *Atlas de Mortalidade por Câncer no Brasil: 1979-1999*. [S.l.]: Ministério da Saúde, 1999.

- INCA. *Estimativas 2008: Incidência de Câncer no Brasil*. [S.l.]: Ministério da Saúde, 2007.
- JAFARI-KHOUSANI, K. et al. Texture analysis of hippocampus for epilepsy. *Medical Imaging*, 2003.
- JAIN, A. K.; FARROKHNI, F. Unsupervised texture segmentation using gabor filters. *IEEE International Conference on Systems, Man and Cybernetics*, p. 14–19, 1990.
- JAIN, A. K.; MURTY, M. N.; FLYNN, P. J. Data clustering: A review. *ACM Computing Surveys*, v. 31, n. 3, set. 1999.
- JULESZ, B. Visual pattern discrimination. *IRE Transactions on Information Theory*, fev. 1962.
- KAUS, M. R. et al. Automated segmentation of mr images of brain tumors. *Radiology*, v. 218, n. 2, p. 586–591, fev. 2001.
- KJAER, L. et al. Texture analysis in quantitative mr imaging. *Acta Radiologica*, v. 36, n. 2, p. 127–135, 1995.
- KOVALEV, V. A. et al. Three-dimensional texture analysis of mri brain datasets. *IEEE Transactions on Medical Imaging*, v. 20, n. 5, maio 2001.
- LERSKI, R. A. et al. Mr image texture analysis - an approach to tissue characterization. *Magnetic Resonance Imaging*, v. 11, p. 873–887, 1993.
- LETTEBOER, M. M. J. et al. Interactive multi-scale watershed segmentation of tumors in mr brain images. *IMIVA*, 2001.
- LI, S. et al. Texture classification using support vector machines. *Pattern Recognition*, n. 36, p. 2883–2893, 2003.
- LIU, H.; YU, L. Toward integrating feature selection algorithms for classification and clustering. *IEEE Transactions on Knowledge and Data Engineering*, v. 17, n. 4, p. 491–501, abr. 2005.
- LORENA, A. C.; CARVALHO, A. C. P. L. F. *Introdução às Máquinas de Vetores de Suporte*. [S.l.], abr. 2003.
- MAHMOUD-GHONEIM, D. et al. Three dimensional texture analysis in mri: a preliminary evaluation in gliomas. *Magnetic Resonance Imaging*, n. 21, p. 983–987, 2003.
- MANJUNATH, B. S.; CHELLAPPA, R. Unsupervised texture segmentation using markov random field models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 13, n. 5, p. 478–482, maio 1991.
- MARTINS, A. C. G. *Apresentação Sonora e Sonificação de Imagens com Texturas*. Tese (Doutorado) — Escola Politécnica da Universidade de São Paulo, 1997.
- MATERKA, A.; STRZELECKI, M. *Texture Analysis Methods - A Review*. [S.l.], 1998.

- MIPAV: Medical Image Processing, Analysis, and Visualization. 2008. (acesso em 04/03/2009). Disponível em: <<http://mipav.cit.nih.gov/>>.
- MOON, N. et al. Automatic brain and tumor segmentation. *MICCAI*, 2002.
- MOORE, A. J.; NEWELL, D. W.; LUMLEY, J. *Neurosurgery Principles and Practice*. [S.l.]: Springer, 2004.
- MUSGRAVE, M. C.; QUINN, A. P. Texture analysis of terrain images using a markov random field model. *IEE Image Processing and its Applications Conference*, jul. 1995.
- NOWAK, R. D. Wavelet-based rician noise removal for magnetic resonance imaging. *IEEE Transactions on Image Processing*, v. 8, n. 10, out. 1999.
- NYUL, L. G.; UDUPA, J. K. On standardizing the mr image intensity scale. *Magnetic Resonance in Medicine*, n. 42, p. 1072–1081, 1999.
- NYUL, L. G.; UDUPA, J. K.; ZHANG, X. New variants of a method of mri scale standardization. *IEEE Transactions on Medical Imaging*, v. 19, n. 2, fev. 2000.
- PARKIN, D. M. et al. Estimating the world cancer burden: Globocan 2000. *Int. J. Cancer*, n. 94, p. 153–156, 2001.
- PARKIN, D. M. et al. Global cancer statistics 2002. *CA Cancer J Clin*, n. 55, p. 74–108, 2005.
- PENG, H.; LONG, F.; DING, C. Feature selection based on mutual information: Criteria of max-dependency, max-relevance, and min-redundancy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 27, n. 8, ago. 2005.
- PENTLAND, A. L. Fractal-based description of natural scenes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 6, n. 6, p. 661–674, nov. 1984.
- PERONA, P.; MALIK, J. Scale-space and edge detection using anisotropic diffusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 12, n. 7, jul. 1990.
- PRASTAWA, M. et al. Automatic brain tumor segmentation by subject specific modification of atlas priors. *Academic Radiology*, v. 10, n. 12, p. 1341–1348, dez. 2003.
- RANDEN, T.; HUSOY, J. H. Filtering for texture classification: A comparative study. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 21, n. 4, abr. 1999.
- RANGAYYAN, R. M. *Biomedical Image Analysis*. [S.l.]: CRC, 2005.
- ROCCHI, M. B. L. et al. Current trends in hape and texture analysis in neurology: Aspects of the morphological substrate of volume and wiring transmission. *Brain Research Reviews*, 2007.
- RUAN, S. et al. Tumor segmentation from a multispectral mri images by using support vector machine classification. *4th IEEE International Symposium on Biomedical Imaging*, p. 1236–1239, 2007.
- SANTOS, J. A. et al. Avaliação textural por ressonância magnética dos tumores da fossa posterior em crianças. *Radiologia Brasileira*, 2004.

- SASIKALA, M.; KUMARAVEL, N.; SUBHASHINI, L. Automatic tumor segmentation using optimal texture features. *IET 3rd AMSIP*, 2006.
- SCHAD, L. R.; BLUML, S.; ZUNA, I. Mr tissue characterization of intracranial tumors by means of texture analysis. *Magnetic Ressonance Imaging*, v. 11, p. 889–896, 1993.
- SCHMIDT, M. *Automatic Brain Tumor Segmentation*. Dissertação (Mestrado) — Universidade de Alberta, 2005.
- SHAHMORAD, A. Y. et al. Automatic brain tumor segmentation using tissue diffusivity characteristics. *4th IEEE International Symposium on Biomedical Imaging*, 2007.
- SHEN, S.; GRANAT, M. H. Preprocessing and segmentation of brain magnetic resonance images. *IEEE Conference on Information Technology Applications in Biomedicine*, 2003.
- SIDHU, S.; RAAHEMIFAR, K. Texture classification using wavelet transform and support vector machines. *IEEE Canadian Conference on Electrical and Computer Engineering*, 2005.
- SLED, J. G.; ZIJDENBOS, A. P. A nonparametric method for automatic correction of intensity nonuniformity in mri data. *IEEE Transactions on Medical Imaging*, v. 17, n. 1, p. 87–97, fev. 1998.
- SMOLA, A. J. et al. *Advances in Large Margin Classifiers*. [S.l.]: MIT Press, 1999.
- TANG, X. Texture information in run-length matrices. *IEEE Transactions on Image Processing*, v. 7, n. 11, nov. 1998.
- TOFTS, P. *Quantitative MRI of the Brain: Measuring Changes Caused by Disease*. [S.l.]: Wiley, 2003.
- TUCERYAN, M.; JAIN, A. K. *The Handbook of Pattern Recognition e Computer Vision*. 2nd. ed. [S.l.]: World Scientific Publishing, 1998.
- VAIDYANATHAN, M. Monitoring brain tumor response to therapy using mri segmentation. *Magnetic Ressonance Imaging*, v. 16, 1997.
- VAPNIK, V. N. *The Nature of Statistical Learning Theory*. [S.l.]: Springer-Verlag, 1995.
- VARMA, M.; GARG, R. Locally invariant fractal feature for statistical texture classification. *IEEE 17th International Conference on Computer Vision*, 2007.
- XUAN, X.; LIAO, Q. Statistical structure analysis in mri brain tumor segmentation. *4th Internation Conference on Image and Graphics*, 2007.
- ZHANG, J.; MA, K.; ER, M. H. Tumor segmentation from magnetic resonance imaging by learning via one-class support vector machine. *IWAIT04*, 2004.
- ZHANG, J.; WANG, L.; TONG, L. Feature reduction and texture classification in mri-texture analysis of multiple sclerosis. *IEEE/ICME*, 2007.
- ZHOU, J. et al. Extraction of brain tumor from mr images using one-class support vector machine. *Proceedings of 2005 IEEE Engeneering in Medicine and Biology 27th Annual Conference*, 2005.

ZHU, Y.; YAN, H. Computerized tumor boundary detection using a hopfield neural network. *IEEE International Conference on Neural Networks*, 1995.

ZITOVÁ, B.; FLUSSER, J. Image registration methods: A survey. *Image and Vision Computing*, n. 21, p. 977–1000, 2003.

ZIZZARI, A.; SEIFFERT, U.; MICHAELIS, B. Detection of tumor in digital images of the brain. *Proceeding of the IASTED*, 2001.

ZONGKER, D.; JAIN, A. Algorithms for feature selection: An evaluation. *Proceedings of IEEE International Conference on Pattern Recognition*, 1996.