

UNIVERSIDADE DE SÃO PAULO

JIHAN MOHAMAD ZOGHBI

**AVALIAÇÃO E SEGMENTAÇÃO TEXTURAL DAS
IMAGENS POR RESSONÂNCIA MAGNÉTICA DOS
TUMORES CRANIANOS**

**SÃO PAULO
2005**

UNIVERSIDADE DE SÃO PAULO

JIHAN MOHAMAD ZOGHBI

**AVALIAÇÃO E SEGMENTAÇÃO TEXTURAL DAS
IMAGENS POR RESSONÂNCIA MAGNÉTICA DOS
TUMORES CRANIANOS**

Monografia apresentada à USP para a Disciplina de Tópicos em Ciência da
Computação no Curso de Bioinformática.

Orientador: Koichi Sameshima

**SÃO PAULO
2005**

AGRADECIMENTO

O presente estudo somente foi tornado possível graças a colaboração de diversas pessoas a quem agradeço a todos.

RESUMO

Neste estudo apresenta-se o processamento e análise na segmentação de imagens voltadas ao diagnóstico médico. Apresenta-se a estrutura da análise de imagem de Ressonância Magnética pelo Software Mazda.

Palavras-chave: Imagem; Ressonância Magnética; Topologia.

SUMÁRIO

Resumo.....	03
1-Introdução.....	05
2- Ressonância Magnética.....	07
2.1- Imagem Digital.....	09
2.2- Topologia Digital.....	21
2.3- Textura de Imagens.....	22
3- Estudo Prático.....	24
3.1- Resultados.....	30
3.2- Discussão dos Resultados.....	35
Conclusão.....	36
Referências Bibliográficas.....	37

1- INTRODUÇÃO

Segundo Batista (2003) a tecnologia da informação é uma referência constante no imaginário do homem contemporâneo, habitante de uma sociedade cada vez mais governada pela velocidade com que as informações circulam numa temporalidade própria das ondas eletromagnéticas e das redes de fibra ótica.

O processamento de imagens é certamente uma área em crescimento. Podendo-se citar: a compreensão de imagens, a análise em multi-resolução e em multi-frequência, a análise estatística, a codificação e a transmissão de imagens, etc.

Um dos objetivos fundamentais para diagnosticar pela imagem é caracterizar os tecidos, isto é, determinar se o tecido de uma região de interesse possui característica normal ou patológica.

Um dos problemas principais em neurocirurgia é a localização da estrutura das regiões críticas do cérebro que está ao redor do tumor para definir aproximadamente o local da cirurgia. A intervenção cirúrgica requisita uma localização cortical precisa, a definição exata da trajetória do alvo e a identificação das delimitações patológico-anatômicas. Hoje, as imagens médicas e as técnicas computacionais estão sendo utilizadas no auxílio em neurocirurgias.

O objetivo desse trabalho é usar os métodos disponíveis e desenvolver outros novos em topologia digital para aplicar na área médica com destaque na reconstrução e segmentação de superfícies de imagens e no reconhecimento de padrões. Operadores Morfológicos serão aplicados para segmentar os dados da imagem. Neste estudo, utiliza-se imagens de ressonância magnética de pacientes com lesão neoplásica cerebral, incluindo tumores primários e metastáticos. A textura dos tecidos afetados pelo tumor é analisada usando segmentação de imagens obtidas pela ressonância magnética. Na ressonância magnética a área tumoral é segmentada em quatro partes: o nódulo, a edema, a área infiltrada e o líquido. O resultado dessa análise pode auxiliar o neurocirurgião e o oncologista em determinar o tipo de tratamento a adotar.

Inicia-se por apresentar os conceitos de imagem digital, destacando os elementos de segmentação e processamento de imagens segue-se pelo estudo prático da análise das imagens por meio do Software Mazda.

2- RESSONÂNCIA MAGNÉTICA

A ressonância magnética produz imagens em todos os planos do corpo, mostrando em detalhes o que se passa nos órgãos ou tecidos do paciente através de um magneto e do uso de ondas de rádio captadas por uma antena especial e enviadas a um computador.

De acordo com Santos (2004), Tomografia Computadorizada (TC) é produzida com raio-X muito colimado que atravessam o paciente e incidem sobre um detector, sendo que como raio X é atenuado pelos tecidos que atravessa e esta atenuação é diretamente proporcional à densidade do tecido, sabendo-se a quantidade inicial de raios X e medindo-se a que "sobrou", pode-se quantificar a densidade das estruturas. As medidas de densidade são feitas em linhas ao redor do paciente. Cada intersecção é calculada, compondo-se uma matriz de pontos de densidade. Cada elemento desta matriz terá a espessura do corte e a largura dependente do número de linhas e colunas que o equipamento é capaz de fornecer.

Alta resolução espacial é conseguida com cortes finos, iguais a ou menores que 3 mm, e uma matriz de 512 colunas por 512 pontos.

Já a Ressonância Magnética, de acordo com (Santos Op. Cit.: 02):

A Ressonância Magnética (RM) é um exame mais versátil pois permite cortes em qualquer plano. O processo de obtenção de imagem da Ressonância Magnética é mais complexo e completamente diferente do da TC. Na Ressonância Magnética a imagem é construída a partir da resposta dos prótons nos núcleos do hidrogênio a um pulso de radiofrequência (RF), após o paciente ter sido colocado num campo magnético muito forte. De acordo com o arranjo molecular, cada próton responde de maneira diferenciada ao pulso de radiofrequência. Assim, o próton de uma molécula de ácido graxo responde mais rapidamente que o de uma molécula de água. Isto ocorre porque a molécula "rigidamente organizada" da gordura tem menor mobilidade que a da água em estado líquido. Entre estes extremos, há toda uma gradação de sinais, o que permite a diferenciação de detalhes muito sutis entre os tecidos. A tendência natural do próton após ter recebido o pulso de radiofrequência é realinhar-se em relação ao campo

magnético ao qual está submetido. Isso é definido como a característica T1 do tecido.

2.1- Imagem Digital

Segundo Vicente (2004) são consideradas imagens eletrônicas todas aquelas em que há algum processo eletrônico na sua geração, como exemplo as imagens geradas por um aparelho de ultra-som, ou as próprias imagens que recebemos pela televisão, que são geradas por uma câmera de vídeo e transmitidas por ondas de rádio. Uma classe especial de imagens eletrônicas é as imagens digitais, que são obtidas eletronicamente, convertidas em dados numéricos e armazenadas ou manipuladas em um computador digital.

Um dos objetivos da área de Visão Computacional é a determinação de características dos objetos representados em uma imagem. Uma grande variedade de problemas é obtida conforme a natureza das imagens e as características a serem obtidas a partir delas.

Segundo Henrique Neto et. al. (2003: 03) a imagem digital:

Refere-se à função bidimensional de intensidade de luz $f(x,y)$, onde x e y denotam as coordenadas espaciais e o valor de f em qualquer ponto (x,y) é proporcional ao brilho (ou nível de cinza) da imagem naquele ponto. A imagem digital pode ser considerada como sendo uma matriz cujos índices de linhas e colunas identificam um

ponto na imagem, e o correspondente valor do elemento da matriz identifica o nível de cinza naquele ponto. Os elementos dessa matriz digital são chamados de elementos da imagem, elementos da figura "*pixels*".

De acordo com Matarredonda (1994) a imagem monocromática, ou simplesmente imagem, refere-se à função bidimensional de intensidade da luz $f(x,y)$, onde x e y denotam as coordenadas espaciais e o valor f em qualquer ponto (x, y) é proporcional ao brilho (ou níveis de cinza) da imagem naquele ponto.

Torna-se útil a visualização da função da imagem em perspectiva com um terceiro eixo representando o brilho.

Usando-se esta convenção para atribuir proporcionalmente valores mais altos para áreas de maior brilho obtém-se a altura dos componentes da figura proporcional ao brilho correspondente na imagem.

Uma imagem digital é uma imagem $f(x, y)$ discretizada tanto em coordenadas espaciais quanto em brilho. Uma imagem digital pode ser considerada como sendo uma matriz cujos índices de linhas e de colunas identificam um ponto na imagem, e o correspondente valor do elemento da matriz identifica o nível de cinza naquele ponto. Os elementos dessa matriz digital são chamados de elementos da imagem, elementos da figura, "*pixels*" ou

"pels", estes dois últimos, abreviações de "*picture elements*" (elementos de figura). Quanto mais *pixels* uma imagem tiver melhor é a sua resolução e qualidade.

As imagens digitais estão diretamente vinculada ao método de obtenção das mesmas, a área representada por um pixel é determinada pela altitude do sistema sensor e pelos parâmetros do campo de visada (IFOV)² do mesmo (Schowengerdt, 1983). O tamanho do IFOV e o espaçamento entre os pixels são uns dos fatores que caracterizam uma imagem digital de sensoriamento remoto.

No processamento da imagem digital, segundo Matarredonda (op. Cit.), o primeiro passo é a aquisição da imagem, isto é, captura da imagem digital.

Para fazer isso, necessita-se de um sensor para imageamento e a capacidade de digitalizar o sinal produzido pelo sensor. Após a obtenção de uma imagem digital, o próximo passo trata de *pré-processar* aquela imagem.

A função chave no pré-processamento é melhorar a imagem de forma a aumentar as chances para o sucesso dos processos seguintes. Nesse exemplo, o pré-processamento tipicamente envolve técnicas para o realce de contrastes, remoção de ruído e isolamento de regiões cuja textura indique a probabilidade de informação alfanumérica.

Segundo Jensen (2000), o objetivo fundamental do processamento digital de imagens envolve a detecção, identificação e mensuração de objetos de uma cena através de aplicações multi-conceitos (multiescala, multitemporal e multiespectral) que envolvem princípios estatísticos para reconhecimento de padrões, modelagem, sistemas de redes neurais, fotogrametria e interpretação de imagens.

O próximo estágio trata da segmentação que divide uma imagem de entrada em partes, em objetos constituintes. Em geral, a segmentação automática é uma das tarefas mais difíceis no processamento de imagens digitais.

Para Espindola (2005: 16):

As técnicas de segmentação são baseadas na definição geral de Zucker (1976) que apresenta quatro condições básicas para o processo: (a) todos os pixels da imagem devem pertencer a uma região, (b) as regiões devem ser conectadas, (c) todos os pixels de uma dada região devem ser considerados similares e (d) o resultado final deve satisfazer todas as três condições enumeradas acima.

Por um lado, um procedimento de segmentação robusto favorece substancialmente a solução bem sucedida de um problema de imageamento. Por outro lado, algoritmos de segmentação fracos

ou erráticos quase sempre asseveram falha no processamento. No caso de reconhecimento de caracteres, o papel básico da segmentação é extrair caracteres individuais e palavras do fundo da imagem.

Para Matarredonda (op. Cit.) a saída do estágio de segmentação é constituída tipicamente por dados em forma de *pixels*, correspondendo tanto à fronteira de uma região como a todos os pontos dentro da mesma.

Em ambos os casos é necessário converter os dados para uma forma adequada ao processamento computacional. A primeira decisão que precisa ser feita é se os dados devem ser representados como fronteiras ou como regiões completas.

2.1.1- Segmentação de Imagem

A segmentação de imagem é uma técnica para dividir a imagem nas regiões significativas que correspondem aos objetos diferentes. Pode-se considerar para ser um processo aglomerando-se onde os pixels sejam classificados em tipos atribuídos do tecido de acordo com seus valores do cinzento-nível e correlação espacial.

Para Albuquerque (2003) segmentar consiste na realidade em dividir a imagem em diferentes regiões, que serão posteriormente analisadas por algoritmos especializados em busca de informações ditas de "alto-nível". Por exemplo cada pixel na imagem pode ser segmentadas em duas regiões: aqueles pertencentes as células e aqueles pertencentes ao fundo da imagem. A imagem obtida neste caso é composta por apenas duas regiões, por exemplo uma região branca (fundo) e outra preta (células/objeto). Esta imagem, com 2 níveis de cinza, é conhecida como Imagem Binária. Devido às grandes facilidades na manipulação deste tipo de imagens, principalmente porque reduzimos significativamente a quantidade de dados, elas são freqüentemente utilizadas no processo de tratamento da informação.

Segundo Wang (2001), o problema principal associado com esta segmentação é que o erro de classificação é elevado quando as imagens observadas de pixel são difusas. Entretanto, pode-se aplicar

função como uma solução inicial desde que o erro de classificação é distribuído uniformemente.

Para Henrique Neto (op. Cit.: 03):

O estágio que trata da segmentação consiste em dividir uma imagem de entrada em partes constituintes para uma melhor caracterização das regiões de interesse.

A saída do estágio de segmentação é constituída tipicamente por dados em forma de pixels, correspondendo tanto à fronteira de uma região como a todos os pontos de dentro da mesma.

A segmentação teve como finalidade extrair regiões de uma imagem colposcópica anormal para uma melhor análise após sua individualização.

Em alguns casos o processo de segmentação não corresponde a uma tarefa simples. Alguns fatores provenientes da aquisição das imagens tornam essa tarefa difícil de ser conduzida a êxito.

De acordo com Gonzáles (2000) a segmentação consiste em usar o computador para definir na imagem recortes automáticos ao redor de objetos de interesse. A segmentação subdivide uma imagem em suas partes ou objetos constituintes. O nível até o qual essa subdivisão deve ser realizada, assim como a técnica utilizada,

depende do problema que está sendo resolvido. Os algoritmos de segmentação permitem achar diferenças entre dois ou mais objetos, e distinguir as partículas umas das outras e do fundo. Esta distinção permitirá ao programa interpretar pixels contíguos e agrupá-los em regiões. Os algoritmos de segmentação para imagens monocromáticas são geralmente baseados em uma das seguintes propriedades básicas de valores de níveis de cinza: descontinuidade e similaridade.

Baatz e Schape (2000) destacam que a eficiência do algoritmo de segmentação está vinculada à extração automática de todos os objetos de interesse. Por outro lado, já Beauchemin e Thomson (1997) apresentam que não existem algoritmos de segmentação convenientes a todos os tipos de imagens, entretanto, há métodos que são adaptados a tipos particulares de aplicação. Assim, a escolha do método de segmentação torna-se uma tarefa estritamente importante na obtenção de um algoritmo apropriado para a segmentação de imagens de sensoriamento remoto.

2.1.2- Compressão de Imagens

Segundo Henrique Neto (op. Cit.) uma grande quantidade de dados é produzida quando uma função de intensidade de luz bidimensional é amostrada e quantizada para criar uma imagem digital. Essa quantidade de dados gerada pode ser tão grande que inviabiliza o armazenamento, o processamento e a comunicação.

Para Henrique Neto (op. Cit.: 02):

A compressão de imagens tem como objetivo reduzir a quantidade de dados necessários para representar uma imagem digital. A base do processo de redução é a remoção de dados redundantes. Do ponto de vista matemático, isto consiste em transformar uma matriz de pixels de duas dimensões num conjunto de dados estatisticamente descorrelacionados. As técnicas de compressão incluem duas grandes categorias: com preservação da informação e com perda. A categoria que trata da compressão com preservação é, indubitavelmente, imprescindível para o armazenamento de imagens médicas, permitindo que a imagem seja comprimida e descomprimida sem perder informação, fator relevante que pode decidir uma determinada impressão diagnóstica.

A compressão de imagens tem como objetivo reduzir a quantidade de dados necessária para representar uma imagem digital. A base do processo de redução é a remoção de dados redundantes. Do ponto de vista matemático, isto corresponde a transformar uma matriz de pixels de duas dimensões num conjunto de dados estatisticamente descorrelacionados. A transformação é aplicada antes do armazenamento ou transmissão da imagem.

2.1.3- Análise

A análise relaciona-se ao tratamento em que existe uma descrição da informação presente na imagem.

Segundo Albuquerque (op. Cit.: 03):

Esta parte é chamada de parametrização e é nela que várias medidas quantitativas (parâmetros) são utilizadas para descrever diferentes informações dentro de uma imagem. Algumas aplicações típicas são: a determinação do número de células presentes em um tecido biológico, o cálculo das formas dos contornos de uma célula ou ainda a determinação da distribuição de uma população específica de um conjunto de células. As técnicas dedicadas a análise de imagens podem variar significativamente segundo a sua complexidade e a necessidade em tempo de processamento. E nesta área que vamos encontrar um nível elevado de complexidade no tratamento da informação. Um exemplo prático é quando da classificação automática de células doentes dentro de um conjunto de células observadas em microscopia.

Para Bailey e Gatrell (1995), a definição da matriz de proximidade, definida pelos elementos $ij w$, leva em consideração as

medidas de proximidade espacial entre áreas adjacentes, sendo que estas medidas podem ser a distância ao centróide da área, as adjacências ou o tamanho das fronteiras de área para uma dada configuração espacial.

2.2- Topologia Digital

Segundo Falcão (2005) a topologia digital é o estudo de propriedades de objeto em imagem digital, as quais não são afetadas por transformações geométricas, exceto aquelas que envolvem junção ou separação de partes do objeto.

A Topologia Digital estuda a aplicação das noções definidas em topologia sobre imagens binárias.

Segundo Ross (1989) a topologia digital consiste em estabelecer a noção de adjacência entre pontos e, a partir desta definição, construir os demais conceitos e propriedades.

2.3- Textura de Imagens

Textura, segundo Santos et. al. (2003), refere-se à informação auxiliar que é obtida por meio de análises estatísticas do padrão de tons de cinza na imagem, e, portanto, diferentes texturas nos auxiliam a reconhecer aspectos distintos dos tecidos.

Na avaliação textural pela ressonância magnética (RM) a designação genérica para uma série de técnicas de pós-processamento das imagens usadas na quantificação da variação espacial dos tons de cinza nas imagens, sendo que essas técnicas foram originalmente desenvolvidas para segmentação por computador de imagens de satélite para fornecer informação sobre a variação espacial dos tons de cinza nas imagens digitais.

De acordo com Santos et. al (op. Cit.: 03):

Os algoritmos utilizados para avaliação textural são divididos em dois grandes grupos: estatísticos e estruturais. No primeiro destes, a caracterização tecidual é feita por intermédio de parâmetros estatísticos considerando as propriedades locais das inter-relações entre os "pixels". Os métodos estruturais procuram determinar os constituintes elementares de textura e suas regras de distribuição¹.

Para a descrição quantitativa dos aspectos da textura, como brilho, micro e macrotextura das imagens de RM, são utilizados parâmetros texturais de primeira e segunda ordens. Os parâmetros de textura de primeira ordem caracterizam a distribuição dos tons de cinza baseados na sua frequência de ocorrência sem considerar suas interdependências espaciais, por intermédio de histogramas de tons de cinza. Os parâmetros de segunda ordem estudam a interdependência espacial entre os tons de cinza, representando a uniformidade espacial e a macrotextura.

A avaliação da textura, visualmente, é particularmente subjetiva, devendo-se considerar, ainda, a limitada sensibilidade que os observadores humanos possuem para propriedades texturais. Técnicas analíticas texturais matemáticas são significativamente mais sensíveis às modificações texturais, além de serem métodos quantitativos, por conseguinte, objetivos.

Há problemas diagnósticos em que a acurácia baseada somente na inspeção visual não é aceitável, levando a uma busca por uma maior especificidade na caracterização patológica dos tecidos nas imagens diagnósticas, com o intuito de se oferecer aos pacientes tratamentos mais efetivos e menos danosos, na medida do possível.

3- ESTUDO PRÁTICO

Selecionou-se um grupo de oito pacientes adultos com diferentes tipos de tumores cerebral. Oito do sexo masculino e uma do sexo feminino. Destes, quatro eram pacientes com GLIOBLASTOMA MULTIFORME, dois pacientes com METASTASE ADENOCARCINOMA, um paciente com OLIGODENDROGLIOMA ANAPLASICO, um paciente com MENINGEOMA, e um com ASTROCITOMA GRAU II(OMS).

Esses pacientes foram encaminhados para a seção de Ressonância Magnética onde foi obtida a imagem. As imagens de RM foram obtidas com bobina de crânio, em equipamento com campo 1.5 Tesla (Signa Horizon LX-GE, Milwaukee, EUA) com gradiente de 23 mt/m. Adquiririam-se imagens com as técnicas spin-eco pesadas em T1 e T2, além de seqüências de inversão recuperação com supressão de liquor (FLAIR), no plano axial. Para melhor caracterização das lesões foram obtidas imagens spin-eco pesadas em T1 adquiridas após a administração de contraste –gadolínio, dose de 0,1 mmol/kg – e realização de fossa posterior no plano axial. Para cada paciente selecionado foram obtidas três regiões de interesse (ROI) nas seqüências pesadas em T2 no plano axial : o tumor, a área infiltrada

(tecido ao redor do tumor), e o tecido normal (fig.1). A administração endovenosa do meio de contraste permitiu uma melhor definição da extensão tumoral, ou seja, a ROI do tumor foi definida a partir das regiões de realce nas imagens pesadas em T1 pós-contraste e, então, transferidas para imagens pré-contraste. Ao todo foram selecionadas 27 ROI.




Figura 1. ROIs no plano axial flair: tecido normal(rosa); tecido normal adjacente à lesão(Azul); Edema (azul escuro); Liquor (verde); Tumor (vermelho).

Após a aquisição dos dados, as imagens foram transferidas para uma estação de trabalho e pós-processadas para

cálculo dos parâmetros de texturas de primeira e segunda ordem, utilizando-se o “software” MaZda. Este “software” foi desenvolvido em 1996 no Institute of Eletronics, Technical University (TUL), Polônia, por Michel Strzelecki e Piotr Szczpinski, estabelecendo quantitativamente o brilho, a microestrutura e a macroestrutura dos tecidos normais e patológicos.

Nesse estudo foi escolhido o seguinte parâmetro de primeira ordem: a media do gradiente absoluto, a variância do gradiente absoluto, Skewness, Kurtosis, e Grads >0 (a porcentagem dos pixels com gradiente diferente do zero). Os parâmetros do gradiente descrevam a distribuição local de diferentes níveis de cinza, isto é, as microestruturas do ROI (3). Para calcular os parâmetros do gradiente foram definidos os seguintes vizinhos de um pixel $x(i, j)$:

A	B	C	D	E
F	G	H	I	J
K	L	x(i, j)	N	O
P	Q	R	S	T
U	V	W	Y	Z

Baseado nessa vizinhança, o valor do gradiente absoluto ($ABS_V(i, j)$) é calculado para cada pixel:

a) Para 5x5 pixel vizinhança:

$$ABS\ V5(i,j) = \sqrt{((W - C)^2 - (O - K)^2)}$$

b) para 3x3 pixel vizinhança:

$$ABS\ V3(i,j) = \sqrt{((R - H)^2 - (N - L)^2)}$$

A definição de $ABS\ V3$ é usada no MaZda na versão 2.13. Para o matriz $ABS\ V=ABS\ V3$ de M elementos (que contém os valores do gradiente absoluto para ROI pixels), os parâmetros do gradiente são definidos como o seguinte:

A média do gradiente absoluto:

$$GrMean = \frac{1}{M} \sum_{i,j \in ROI} ABS\ V(i,j)$$

A variância do gradiente absoluto:

$$GrVariance = \frac{1}{M} \sum_{i,j \in ROI} (ABS\ V(i,j) - GrMean)^2$$

Skewness do gradiente absoluto:

$$GrSkewness = \frac{1}{(\sqrt{GrVariance})^3} \frac{1}{M} \sum_{i,j \in ROI} (ABS\ V(i,j) - GrMean)^3$$

Kurtosis do gradiente Absoluto:

GrKurtosis =

$$\frac{1}{(\sqrt{GrVariance})^4} \frac{1}{M} \sum_{i,j \in ROI} (ABS\ V(i, j) - GrMean)^4 - 3$$

onde o ROI é a região de interesse.

Grads > 0 onde a percentagem de elementos do matriz ABSV é diferente do zero.

Entre os parâmetros de segunda ordem utiliza-se: **Run-length Nonuniformity (RLN)**, isso é calculado quatro vezes para cada ROI e em quatro direções: horizontalmente, verticalmente, com 45 grau e 135 grau; run length nonuniformity (RLNonUni) que trata da inter-relação entre os pixels, considerando a sua intensidade e distribuição em uma matriz. Seja $p(i, j)$ o número de vezes que ocorre uma corrida de comprimento j com nível de cinza i . Seja N_g o valor de níveis de cinzas e N_r o número de corridas. As definições dos parâmetros de run-length matrix $p(i, j)$, como adotado no MaZda é o seguinte:

Run-length Nonuniformity:

$$RLNonUni = \left(\sum_{j=1}^{N_r} \left(\sum_{i=1}^{N_g} p(i, j) \right)^2 \right) / C .$$

O Mazda promoveu a análise destes parâmetros de texturas nas ROI selecionadas nas seqüências pesadas em T2, estabelecendo, quantitativamente, o brilho, a micro e a macroestrutura dos tecidos normais e patológicos. Posteriormente, os dados obtidos foram analisados pelo teste estatísticos usando o Microsoft Excel para a determinação das diferenças estatísticas entre eles.

3.1 - Resultados

Paciente	GRmean			GRVariance		
	TN	TAT	Tumor	TN	TAT	Tumor
1	0,50971	0,24357	0,58183	0,3202	0,22818	0,36566
2	0,301	0,72433	1,2375	0,25151	0,69041	0,93168
3	0,46018	0,56798	0,51375	0,32469	0,35024	0,33165
4	0,31682	0,31786	0,42489	0,31682	0,31786	0,42489
5	0,57733	0,88509	0,52681	0,32719	0,59161	0,34492
6	0,56651	0,9142	0,6544	0,3249	0,42306	0,38127
7	0	0,013029	0,39743	0	0,01286	0,32481
8	0,57582	0,40023	0,55307	0,3604	0,31881	0,34843
9	0,5185	0,44672	0,082871	0,34897	0,3271	0,084969
Media	0,4251	0,50145	0,5052	0,2861	0,3622	0,3931
DP	0,1907	0,30076	0,3048	0,1114	0,1966	0,2235

Tabela 1 Resultados: GRmean e GR variance

TN, tecido normal distante da lesão; TAT, tecido normal perifericamente á lesão

O resultado do teste estatístico mostrou uma diferença estatisticamente significativa entre as três regiões (TN, TAT, Tumor) quando usamos os parâmetros GrSkewness e Grkurtosis onde os $P < 0.000016045$ (tabela 2). Quando consideramos: o tecido normal e o tecido adjacente ao tumor, e o tecido adjacente ao tumor e o tecido normal o parâmetro 135dr_RLNonUni verificou $p=0.009$ e $p=0.03$ correspondente (tabela 5) .

Tabela 2 Resultados: GrSkewness e GrKurtosis

Paciente	GrSkewness			GrKurtosis		
	TN	TAT	Tumor	TN	TAT	Tumor
1	0,31661	1,5455	0,28619	-1,6695	0,62327	-1,4093
2	1,1564	1,0042	0,77169	0,44032	0,47528	0,68326
3	0,53306	0,19839	0,33808	-1,5019	-1,7328	-1,6596
4	-,27923	-0,69753	-0,017961	0,069492	0,65375	0,063766
5	0,10153	0,22394	0,32766	-1,7375	-1,0192	-1,6741
6	0,12974	-0,11173	0,1782	-1,7344	-0,70859	-1,2739
7	0	8,5886	0,8941	0	71,763	-0,8038
8	0,22167	0,79706	0,24409	-,6586	-1,1686	-1,716
9	0,36887	0,59974	3,344	-1,6534	-1,4333	9,6661
Media	0,2832	1,3498	0,7073387	-0,938	7,4948	0,2085
DP	0,4016	2,79166	1,0289269	0,9022	24,118	3,6447

Parâmetro	Grads >0.0		
Paciente	TN	TAT	Tumor
1	0.46	0.2125	0.50262
2	0.27193	0.51613	0.76852
3	0.40625	0.49383	0.45588
4	0.80851	0.88372	0.80882
5	0.51852	0.63235	0.45918
6	0.51042	0.71765	0.55952
7	0	0.013029	0.34138
8	0.49554	0.34454	0.48148
9	0.44828	0.39019	0.076531
Media	0,4355	0,4671	0,2177
DP	0,216	0,26427	0.494

Tabela 4 TN, tecido normal distante da lesão; TAT, tecido normal perifericamente á lesão

Parâmetro	Horzl_RLNonUni			Vertl_RLNonUni		
	TN	TAT	Tumor	TN	TAT	Tumor
1	8,8387	3,2703	17,459	5,5778	3,1212	10,978
2	3,7407	4,4286	11,64	4,037	10,073	29,806
3	4,8605	8,0833	4,125	8,7736	4,9444	7,6667
4	11,816	16,9	15	10,021	10,576	13,4
5	8,0741	6,7273	4,1111	5,5581	13,567	7,4615
6	4,619	5,5806	4,871	11,127	12,375	7,5263
7	4,3333	4,6154	4,375	2,8889	3	11,649
8	13,341	6,7959	7,7347	5,4167	8,3208	4,4359
9	11,575	13,414	2,7	8,2571	7,5854	3,2308
Media	7,9109	7,75727	8	6,8508	8,1736	10,684
DP	3,6976	4,52081	5	2,8056	3,8602	7,8906

Tabela 4 TN, tecido normal distante da lesão; TAT, tecido normal perifericamente á lesão

Parâmetro	45dgr_RLNonUni			135dr_RLNonUni		
	TN	TAT	Tumor	TN	TAT	Tumor
1	10,562	6,0833	24,786	12,803	3,6667	27,865
2	7	14,608	30,413	5,9143	12,83	44,864
3	14,083	8,5094	9,8235	10,143	10,931	8,5686
4	16,673	13,229	13,095	22,419	14,892	32,065
5	13,348	13,952	8,0952	12,415	20,027	8,619
6	13,232	10,05	7,6316	13,714	24,2	13,52
7	5,1379	4,625	20,071	5,1379	4,5	9,9474
8	21,673	8,0714	9,2759	10,972	17,932	11,194
9	18,364	22,841	3,8125	12,874	16,117	4,25
Media	13,341	11,3299	14	11,821	13,9	17,877
DP	5,2624	5,55008	9	5,0177	6,7899	13,757

Tabela 5 TN, tecido normal distante da lesão; TAT, tecido normal perifericamente á lesão

3.2- Discussão dos Resultados

A avaliação das imagens pelo Software Mazda mostraram-se capazes de destacar a distinção entre tecido normal e tecidos patológicos, já de discriminação entre tecido tumoral e edema a partir dos parâmetros analisados não obteve o mesmo resultado.

Segundo Santos et. al (op. Cit.:04)

Kjaer *et al.* apresentaram resultados mais promissores em 1994, ao compararem seis voluntários saudáveis com 88 pacientes portadores de tumores intracranianos primários e metastáticos, demonstrando ser possível a diferenciação entre tecido tumoral e edema, quando diferentes parâmetros texturais eram combinados.

CONCLUSÃO

Neste estudo discutiu-se técnicas de processamento de imagens, sendo que devem-se destacar que na prática o processamento de imagens é uma técnica extremamente dependente do problema que quer-se resolver.

Como qualquer técnica em seu início há muito perspectivas futuras para estudar, a utilização dos parâmetros estatísticos para caracterizar as texturas dos tecidos patológicos esta ficando cada vez mais útil. Atualmente analisa-se as imagens MR em 2D, mas futuramente os métodos desse trabalho vão ser utilizados em 3D. Em estudos futuros está no planejamento o desenvolvimento de um programa que recebe as imagens e analisa as texturas do tecido de um tumor em qualquer parte do corpo.

Concluindo, espera-se que os dados apresentados neste estudo possa ser realmente colocada em prática de forma a agilizar a topologia digital para aplicação na área médica.

REFERÊNCIAS BIBLIOGRÁFICAS

ALBUQUERQUE, Marcio. **Processamento de Imagens: Métodos e Análises**. Rio de Janeiro: Centro Brasileiro de Pesquisas Físicas, 2003.

BAILEY, T.; Gatrell, A. **Interactive Spatial Data Analysis**. London: Longman Scientific and Technical, 1995.

BATISTA, Cicélia. **O Mundo Possível na Tela**. Salvador: UFBA, 2003.

BEAUCHEMIN, M.; Thomson. The evaluation of segmentation results and the overlapping area matrix. **International Journal of Remote Sensing**. v. 18, n. 18, p. 3895-3899, December, 1997.

CÂMARA, G.; Fucks, S.; Carvalho, M.; Monteiro, A. **Análise Espacial de Dados Geográficos**. São José dos Campos. INPE, 2003 (3a. edição, revista e ampliada).2004.

CÂMARA, G.; Souza, R.C.M.; Freitas, U. M.; Garrido, J. C. P. SPRING: integrating remote sensing and GIS with object-oriented data modeling. **Computer and Graphics**, v.15, n.6, 13-22 p., 1996.

EVANGELOU, I. E.; Hadjimitsis, D.G.; Lazakidou, A.; Clayton, C. I. Data mining and knowledge discovery in complex image data using artificial neural networks. In: International Conference on Logic Programming, 17, Workshop on Complex Reasoning on Geographical Data (ICLP'01), 26 November – 1 December 2001, Paphos, Cyprus.

GIL, Victor M.S.; Geraldles, Carlos F.G.C. **Ressonância Magnética Nuclear.**

Métodos e Aplicações. Fundação Calouste Gulbenkian, Lisboa, 2004.

GONZALEZ R.; WOODS, R. **Processamento de Imagens Digitais.** São Paulo: Atlas, 2000.

HARRIS, Robin K. **Nuclear Magnetic Resonance Spectroscopy.** A Physicochemical View, Longman, London, 1996.

HU, Y.; Dennis, T. J. Textured image segmentation by context enhanced clustering. **Vision, Image and Signal Processing, IEE Proceedings.** v. 141, n. 6, p. 413- 421, December, 1994.

JENSEN, J. R. **Introductory digital image processing: a remote sensing perspective.** New Jersey: Prentice Hall, 1986. 379p.

JENSEN, J. R. **Remote sensing of the environment: an earth resource perspective.** New Jersey: Prentice Hall, 2000. 544p.

Kurz, L.; Benteftifa, H. **Analysis of variance in statistical image processing.** Cambridge: Cambridge University Press, 1997.

LUCCA, E. V. D. **Avaliação e comparação de algoritmos de segmentação de imagens de radar abertura sintética.** São José dos Campos. 207p. (INPE-7507- TDI/721). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, 1998. .

MATARREDONA, E. **O Uso do Processamento de Imagens Aplicadas na Radiologia Médica.** São Paulo: Artes Médicas, 1994.

MATHER, P. M. **Computer processing of remotely-sensed images: an introduction.** New York: John Wiley & Sons, 1999.

MEDEIROS, N. G.; Silva, E. A.; Nogueira, J. R. Segmentação morfológica de imagens utilizando o gradiente morfológico multi-escala. **Revista Brasileira de Cartografia.** n.54, 2003.

OLIVEIRA, J. C. **Índice para avaliação de segmentação (IAVAS): uma aplicação em agricultura.** São José dos Campos. 160p. (INPE-9554-TDI/830). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, 2002.

PEKKARINEN, A. A method for the segmentation of very high spatial resolution images of forested landscapes. **International Journal of Remote Sensing.** v. 23, n. 14, p. 2817-2836, July, 2002.

RICHARDS, J. A. **Remote sensing digital image analysis: an introduction.** Kensington: Springer-Verlag Berlin Heidelberg, 1986.

SAMPAIO, R; CATALDO, E.; RIQUELME, R. **Introdução à Análise e ao Processamento de Sinais Usando o MATLAB.** São Paulo: USP, 1998.

SANTOS, Joelson et. al. **Avaliação textural por ressonância magnética dos tumores da fossa posterior em crianças.** São Paulo: Scielo, 2003.

SLICHTER, C. P. **Principles Of Magnetic Resonance,** Springer International, Berlin, 1999.

