



# **Aplicação de Análise de Texturas na Segmentação de Tumores de Cérebro em Imagens por Ressonância Magnética**

Campos do Jordão, 01 de Dezembro de 2008

**Maryana de Carvalho Alegro**  
**Prof. Dra. Roseli de Deus Lopes**



**USP**





# Agenda

- Introdução e Objetivos
- Proposta
- Resultados Obtidos
- Conclusões



# Introdução



# Introdução

- Tumores de cérebro: exames por imagem são a principal ferramenta
- Década de 90: Tomografia Computadorizada
- Atualmente: Ressonância Magnética é a modalidade padrão para imageamento do SNC:
  - alto grau de detalhamento anatômico
  - obtenção de secções em diferentes ângulos
  - radiação não-ionizante
  - maior facilidade de acesso à tecnologia



# Motivação

- Dificuldade no cálculo do volume da lesão
- Dificuldade na reprodutibilidade do resultado de delimitação das bordas
- Dificuldade na comparação entre exames novos e antigos para atestar evolução da doença
- Motivos:
  - segmentação manual dos tumores fatia por fatia
  - segmentação e diagnóstico sofrem influencia de características pessoais do médico (experiência, fadiga, distração, etc)



# Objetivo

**Criar um método para segmentar tumores de cérebro em imagens de ressonância magnética aplicando-se informações de textura na classificação dos tecidos**



# Motivação

- Alteração dos tempos de relaxamento da ressonância, devido à presença de tecido tumoral: alteração na imagem captada
- Diferenças texturais visualmente imperceptíveis
- Cálculo matemático permite extração de informação não perceptível ao olho humano



# Análise de Textura

- O que são texturas?

**“a variação de dados em escalas menores que a escala de interesse” (Petrou,2006)**

- Características inerentes à maioria dos objetos
- Visão humana apresenta facilidade na distinção/percepção de texturas com semelhanças de estatísticas espaciais de primeira e segunda ordem



# Principais Métodos de Análise de Textura

- **Métodos Estatísticos:** caracterizam a textura por sua distribuição espacial e relação entre os níveis de cinza
- **Métodos Baseados em Modelos:** procuram modelar as texturas por métodos matemáticos e estimar seus parâmetros
- **Métodos Estruturais:** dedução de “gramática” de posicionamento de uma primitiva
- **Métodos Baseados em Transformada:** supõe que as texturas podem ser identificadas por suas distribuições de energia no domínio da frequência



# Proposta



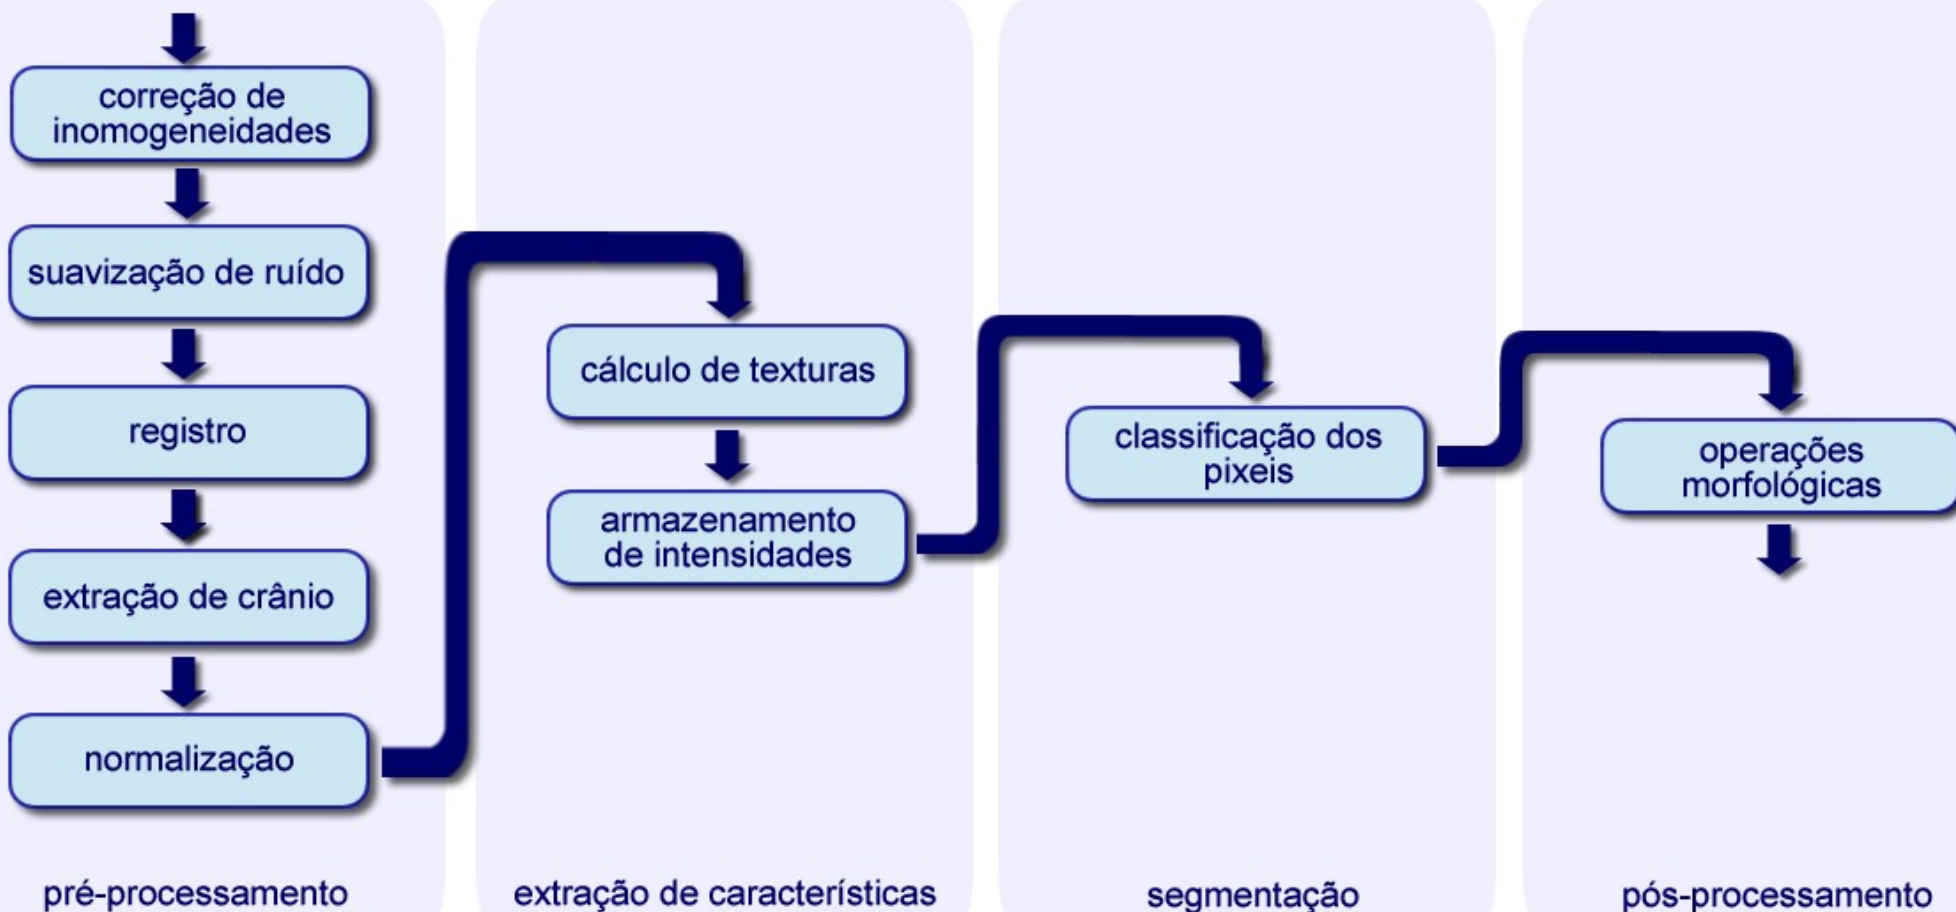
# Proposta

- Adoção de imagens comuns à prática médica
- Realização de processamento “multi-canal”
- Emprego de imagens T1, T1c e FLAIR como diferentes canais de informação
- Todas as etapas devem ser capazes de realizar o processamento “multi-canal” das imagens de teste



# Proposta

Sistema dividido em 4 etapas básicas:





# Pré-processamento

- Etapa mais complexa do sistema
- Deve lidar com os artefatos inerentes às imagens de ressonância
- Prepara imagens de forma a permitir a obtenção de segmentações mais precisas
- Sub-processos
  - correção de inhomogeneidade
  - suavização de ruído
  - registro
  - extração da caixa craniana
  - normalização de intensidades



# Extração de Características

- Tipos de parâmetros mais utilizados em processamento de imagens biomédicas:
  - estatísticos
  - baseados em modelos
  - baseados em transformadas
- Características extraídas nessa etapa: **estatísticas**
  - são as mais utilizadas
  - apresentam bons resultados na literatura
  - energia, contraste, correlação, entropia, homogeneidade, soma das médias, intensidade



# Segmentação

- Separa os pixels em 2 classes: **tumor** e **não-tumor**
- Usa as características extraídas para classificar os pixels
- Uso de Máquinas de Vetor de Suporte:
  - aprendizado supervisionado
  - robustez em grandes dimensões
  - boa capacidade de generalização
  - teoria bem definida



# Pós-processamento

- Filtragem da imagem através de operações morfológicas (dilatação, erosão, abertura, fechamento)
- Retira estruturas não pertencentes à região de tumor, geradas por classificações erradas
- Melhora a precisão da segmentação obtida



# Materiais Utilizados

- 11 datasets de RM em orientação axial (T1, T1c e FLAIR) em DICOM
- Diferentes tipos de tumor, confirmados histologicamente: 4 glioblastomas multiformes, 2 astrocitomas de grau II, 1 meningioma, 1 meduloblastoma, 1 metacarcinoma, 1 pnet e 1 ependimoma
- Segmentação manual dos tumores, realizada por um radiologista experiente
- Matlab e toolbox de Processamento de Imagens
- Ferramenta MIPAV



# Resultados Obtidos



# Conjuntos de Teste

- 11 conjuntos de teste: #1 ao #11
- Cada um contendo 3 imagens T1, 3 imagens T1c e 3 imagens FLAIR
- Todos os conjuntos foram submetidos ao pré-processamento
- Texturas calculadas para cada pixel da região cerebral, com auxílio de uma janela de 9x9
- Testes realizados utilizando a técnica *leave-one-out*









# Características Extraídas

**energia**






**correlação**

**homogeneidade**







**T1**



**T1c**



**FLAIR**



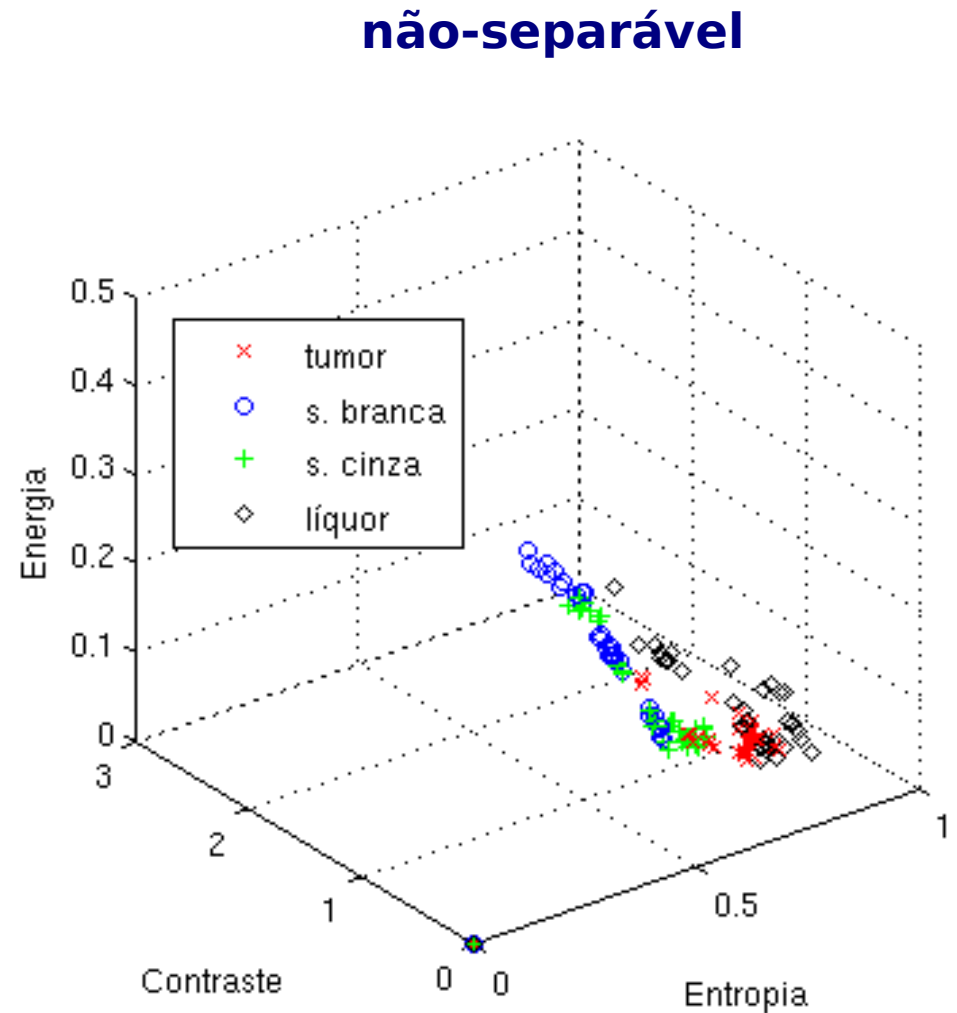
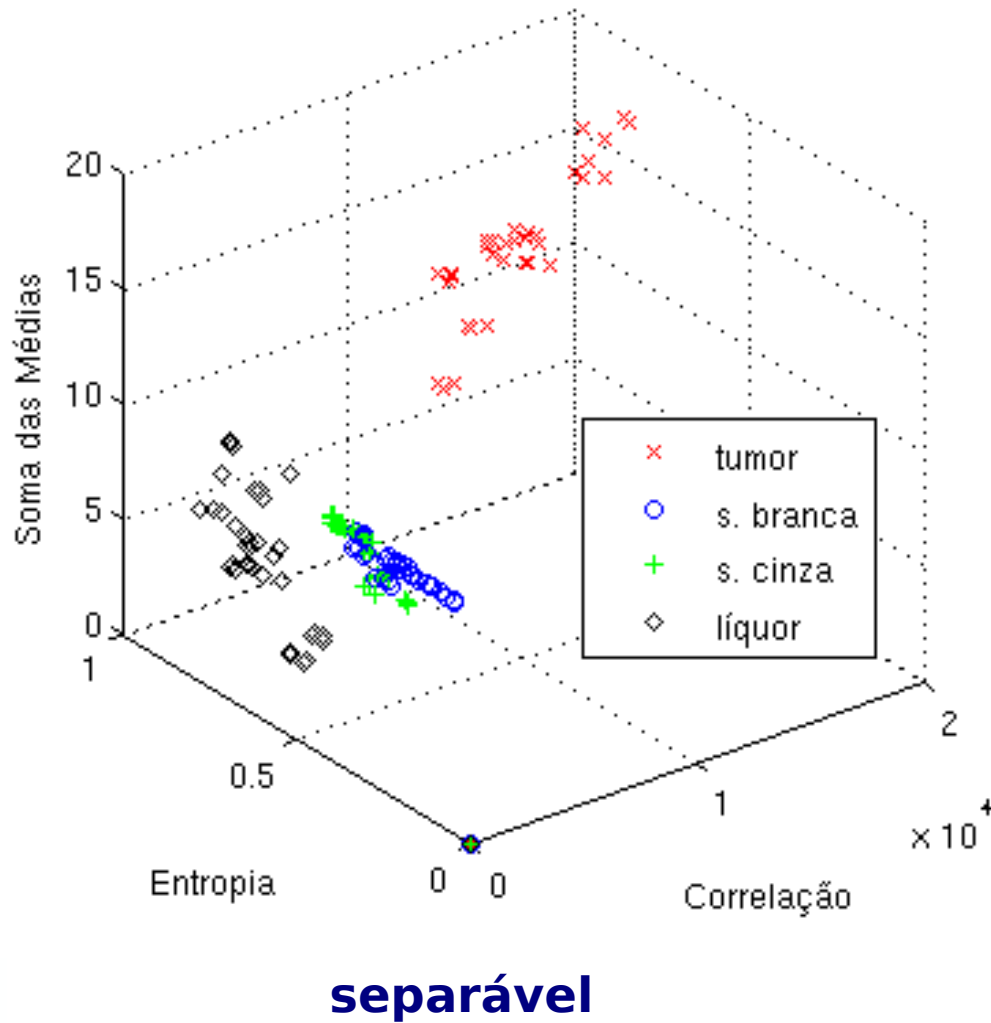
**contraste**

**entropia**

**soma  
das  
médias**




# Separabilidade vs. Não Separabilidade





# Segmentação Final





# Acerto do Classificador

Taxa de acerto do classificador durante a etapa de segmentação

Conjunto	Pixeis classificados corretamente (%)			
	Imagem 1*	Imagem 2*	Imagem 3*	Média
#1	91,2694	87,9187	86,3241	88,5041
#2	94,1735	92,1747	92,6338	92,9940
#3	77,7778	72,1677	82,0496	77,3317
#4	87,4357	88,6314	91,0497	89,0389
#5	72,0670	78,8010	82,3092	77,7257
#6	85,7191	71,2464	81,2482	79,4046
#7	65,1294	77,0261	72,7397	71,6317
#8	93,8317	81,0442	90,0804	88,3188
#9	88,7426	86,8951	85,6198	87,0858
#10	67,4846	76,3345	78,3915	74,0702
#11	88,4349	86,8192	93,6844	89,6462
			<b>Med. Total</b>	83,2502



# Conclusões

- A proposta apresentada obteve resultados satisfatórios
- A proposta apresentada mostrou-se apta a tratar o problema considerado
- Foi possível realizar uma “segmentação automática” do tecido tumoral



# Referências Bibliográficas

- (Clark, 1998) Automatic tumor segmentation using knowledge based techniques. IEEE Transactions on Medical Imaging, v. 17, n. 2, p. 238–251, abr. 1998.
- (Haralick, 1973) Textural features for image classification. IEEE Transactions on Systems, Man, and Cybernetics, 1973.
- (Nyul, 1999) On standardizing the mr image intensity scale. Magnetic Resonance in Medicine, n. 42, p. 1072–1081, 1999.
- (Nyul, 2000) New variants of a method of mri scale standardization. IEEE Transactions on Medical Imaging, v. 19, n. 2, fev. 2000.
- (Schad, 1993) Mr tissue characterization of intracranial tumors by means of texture analysis. Magnetic Resonance Imaging, v. 11, p. 889–896, 1993.
- (Lerski, 1993) Mr image texture analysis - an approach to tissue characterization. Magnetic Resonance Imaging, v. 11, p. 873–887, 1993.
- (Santos, 2004) Avaliação textural por ressonância magnética dos tumores da fossa posterior em crianças. Radiologia Brasileira, 2003.
- (Iftekharuddin, 2006) Brain tumor detection in mri: Technique and statistical validation. IEEE ACSSC 06, 2006.
- (Petrou, 2006) Image Processing: Dealing with Texture. Willey, 2006.



# Perguntas?!