

Segmentação de Texturas por Análise de Complexidade¹

André Ricardo Backes, Odemir Martinez Bruno

Universidade de São Paulo

ICMC - Instituto de Ciências Matemáticas e de Computação

Departamento de Computação e Estatística

backes@icmc.usp.br, bruno@icmc.usp.br

Resumo: A textura constitui um dos principais atributos visuais presentes em uma imagem, sendo capaz de distinguir regiões e contribuindo para o processo de reconhecimento, análise, descrição e classificação de imagens digitais. Neste artigo são apresentados dois métodos de análise e segmentação de textura baseados em medidas de complexidade. Os métodos propostos são baseados em fractais e utilizam as medidas de lacunaridade e dimensão fractal (BoxCounting) para aferir a complexidade das imagens e, por meio desta, gerar assinaturas digitais para representar e segmentar regiões da imagem. Neste trabalho são apresentados exemplos dos métodos aplicados em imagens reais, onde foram utilizadas imagens médicas, e também em imagens sintéticas compostas por mosaicos com texturas de Brodatz.

Pavavras-Chaves: Dimensão Fractal, Lacunaridade, Gliding-box, Análise de Complexidade, BoxCounting, Textura, Análise de Aglomerados.

Texture Segmentation by Complexity Analysis

Abstract: The texture is one of the most important visual attributes existent in an image, being capable to separate regions and contributing to the process of recognizing, analysis, description and classification of digital images. In this article are presented two methods of analysis and segmentation of textures based on complexity measures. The proposed methods are based on fractals and they use lacunarity and fractal dimension (BoxCounting) to measure the complexity of images and, by this way, to generate digital signatures to represent and segment the regions of a image. In this work are presented some examples of these methods applied on real images, where were used medical images, and also synthetic images composed by textures of Brodatz.

Keywords: Fractal Dimension, Lacunarity, Gliding-box, Complexity Analysis, BoxCounting, Texture, Cluster Analysis.

(Received November 18, 2005 / Accepted February 07, 2006)

1. Introdução

Diversas aplicações relacionadas ao reconhecimento de padrões necessitam de métodos que possibilitem quantificar os atributos visuais obtidos durante os processos de análise de imagens.

Dentre os principais atributos visuais presentes numa imagem, encontramos a textura. Este atributo está diretamente relacionado à distribuição e organização dos pixels de uma determinada região da imagem, atuando dessa maneira como uma excelente ferramenta para segmentar regiões ou ainda, como métrica a ser utilizada no reconhecimento de padrões. A literatura nos fornece diversas abordagens que analisam este atributo visual entre as quais se destacam: Campo Aleatório de Markov [13], Redes Neurais [14], Wavelet [1] [15] e momentos Invariantes [11].

Neste artigo é apresentado um estudo comparativo sobre o uso da lacunaridade e da dimensão fractal (obtida através da técnica de BoxCounting) como métodos para a caracterização de texturas, permitindo identificar e segmentar imagens por suas diferentes texturas. Os métodos e suas respectivas implementações são discutidos, bem como os resultados obtidos, ilustrando o potencial das técnicas empregadas.

2. Textura

A textura constitui uma característica diretamente relacionada com as propriedades físicas que a superfície de um objeto apresenta. Ela descreve o padrão de variação de tons de cinza ou cor numa determinada área. Trata-se de um termo intuitivo e de largo emprego, mas que, apesar de sua grande importância, não possui uma definição precisa [8].

Uma textura se caracteriza pela repetição de um modelo sobre uma região, sendo este modelo repetido em sua forma exata ou com pequenas variações. Através de sua análise é possível distinguir regiões que

apresentem as mesmas características de refletância, e portando, mesmas cores em determinada combinação de bandas. Isso torna a textura um excelente descritor regional, contribuindo para uma melhor precisão dos processos de reconhecimento, descrição e classificação de imagens. Apesar de seus benefícios, seu processo de reconhecimento exige um alto nível de sofisticação e complexidade computacional [8]. Diversas abordagens encontradas na literatura operaram sobre texturas, realizando análise ou segmentação. Tais métodos, em geral, são baseados na análise estatística dos pixels de uma região [13], análise de espectro [3], wavelets [1] [15] e dimensão fractal [5].

Nesse trabalho são utilizadas as técnicas de lacunaridade e dimensão fractal (BoxCounting) afim de obter uma assinatura para as texturas analisadas. Tais assinaturas serão utilizadas na segmentação das imagens em diferentes regiões de similaridade, sendo essas regiões obtidas através do uso de análise de aglomerados sobre as assinaturas.

3. BoxCounting

Devido a sua simplicidade e facilidade de implementação, o BoxCounting é um dos métodos mais conhecidos e utilizados para estimar a dimensão fractal de objetos e imagens. Sua aplicação consiste em sobrepor uma malha de quadrados à forma sob análise, de modo a obter o número de quadrados necessários para cobri-la [6].

Dado uma forma A , o número de caixas que contém parte da forma A , $N_r(A)$, varia de acordo com o tamanho da caixa, r , seguindo a relação

$$N_r(A) = \mu \cdot r^{-D}$$

A partir da relação acima, é possível estimar a dimensão fractal D como sendo

$$D = -\lim_{r \rightarrow 0} \frac{\ln(N_r(A))}{\ln(r)}$$

Tal solução adiciona o problema do cálculo de um limite. Esse problema pode ser resolvido adaptando-se o cálculo do limite para um espaço discreto, onde a contagem de caixas, $N_r(A)$, é realizada para diferentes valores de r . Faz-se então necessário definir um conjunto B com os vários tamanhos de lados r que serão utilizados nas diversas iterações do método. Tal conjunto pode ser definido inicialmente pelo usuário do método. No entanto, é padrão calculá-lo com base nas dimensões da forma sob análise, de modo que:

$$\forall r_i \in B \begin{cases} r_0 = \max(\text{altura}, \text{largura}) \\ r_{i+1} = r_i / 2 \end{cases}$$

A partir da regressão do gráfico log-log de $N_r(A)$ (número de caixas ocupadas por r (tamanho do lado dessa caixa) obtém-se a aproximação de uma reta, cujo coeficiente angular é α . Deste modo, é possível definir $D = -\alpha$ como sendo a dimensão fractal de A [17] [9].

De modo a utilizar o BoxCounting sobre imagens em tons de cinza, considerou-se a intensidade do pixel como a altura daquele ponto da imagem. A partir dessa alteração, ao invés de dividir a imagem em caixas de lado r , optou-se por dividi-la em cubos de lado r . Isso produziu um novo $N_r(A)$, sendo este agora o número de cubos que possuem parte da imagem. Apesar da implementação dessa modificação, o restante do cálculo manteve-se inalterado.

4. Lacunaridade

A lacunaridade constitui uma medida baseada no grau de invariância a translação que um fractal apresenta. Ela caracteriza a maneira como os pixels estão distribuídos e organizados em uma determinada

região da imagem, ou seja, ela quantifica como o espaço está preenchido, diferente da dimensão fractal que mede o quão preenchido está o espaço. De fato, a lacunaridade pode ser compreendida como um complemento da dimensão fractal, uma vez que formas com a mesma dimensão fractal podem apresentar diferentes valores para a lacunaridade [16].

A lacunaridade é obtida medindo-se a distribuição espacial dos buracos existentes na imagem. Por meio dela é possível quantificar a homogeneidade de uma imagem ou de parte dela, de modo a torná-la comparável com outras imagens [2] [16]. Um dos algoritmos mais populares para se estimar a lacunaridade é o Gliding-box [16]. Esse algoritmo faz uso dos momentos de probabilidade de primeira e segunda ordem da imagem a fim de estimar a sua lacunaridade.

O algoritmo do Gliding-box é similar ao algoritmo do BoxCounting utilizado para estimar a dimensão fractal. Nele, uma caixa de lado r é colocada sobre o canto superior esquerdo da imagem e o número de pontos da imagem é contado. Esse processo é repetido para todas as linha e colunas da imagem, produzindo uma distribuição de frequência da massa da imagem. O número de caixas de lado r contendo uma massa S da imagem é designado por $n(S, r)$, sendo o total de caixas contadas designado por $N(r)$. Essa distribuição de frequência é então convertida para uma distribuição de probabilidade $Q(S, r)$, onde

$$Q(S, r) = n(S, r) / N(r)$$

O primeiro e o segundo momentos dessa distribuição são determinados como:

$$Z^{(1)} = \sum SQ(S, r)$$

$$Z^{(2)} = \sum S^2 Q(S, r)$$

A lacunaridade para uma caixa de tamanho r é então definida como:

$$\Lambda(r) = Z^{(2)} / (Z^{(1)})^2$$

Outras características relativas a lacunaridade podem ser obtidas alterando o tamanho da caixa utilizada no Gliding-box [16].

De modo a utilizar o Gliding-box sobre imagens em tons de cinza, foi considerado a intensidade de um pixel como a altura daquele ponto da imagem. A partir dessa alteração, ao invés de deslizarmos uma caixa de lado r por todas as linhas e colunas da imagem, optou-se por deslizar um cubo de lado r por todas as linhas, colunas e altura da imagem. Isso produziu uma nova distribuição de frequência da massa da imagem, $n(S,r)$, e um novo $N(r)$, sendo esse novo $N(r)$ a representação do total de cubos contados. Apesar da implementação dessas modificações, o restante do cálculo manteve-se inalterado.

5. Assinatura

A assinatura de uma imagem pode ser definida como uma função ou matriz simplificada que consiga representar ou caracterizar a mesma. Em geral as técnicas utilizadas realizam transformações $T : I^2 \rightarrow R$ ou $T : I^2 \rightarrow I$, onde a função ou vetor de característica obtido é capaz de representar e caracterizar a imagem. Exemplos e teorias sobre assinaturas podem ser encontrados em [4] [11].

Neste trabalho a lacunaridade e o BoxCounting são utilizadas como técnicas plausíveis de caracterizar uma imagem pela sua textura. Deste modo foram consideradas neste trabalho como técnicas de assinatura da textura de imagens.

Tanto a lacunaridade quando a dimensão fractal por BoxCounting, ainda podem ser exploradas com uma abordagem multiescala, permitindo obter assinaturas que aferem o comportamento da imagem, região ou objeto em função da escala de observação. Isto é possível,

através do cálculo da lacunaridade ou do BoxCounting para diferentes tamanhos de caixas, uma vez que ambas são características dependentes da escala. Deste modo, é possível representar o comportamento da textura de uma imagem por uma função 1-D que relaciona o tamanho da caixa utilizada no cálculo com o valor da lacunaridade ou da dimensão fractal obtido, apresentando informações multiescala (Figura 1).

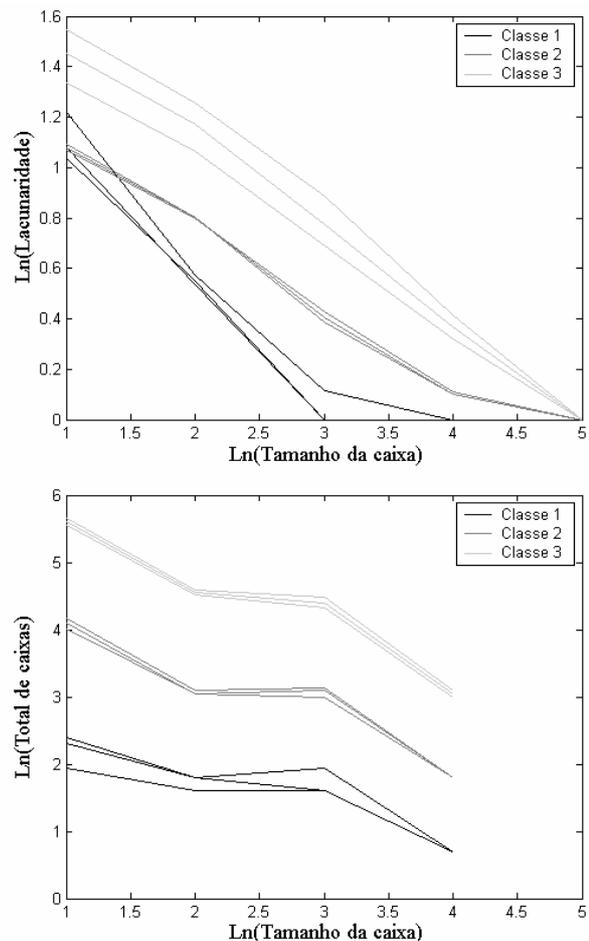


Figura 1: Gráficos log-log da lacunaridade e da dimensão fractal pelo tamanho da caixa.

6. Análise de Aglomerados

A análise de aglomerados é utilizada na Ciência da Computação em problemas que envolvam classificação de dados multivariados. Estes surgem

freqüentemente em áreas como mineração de dados, processamento de imagens, visualização científica e entre outras. Existem diversos algoritmos para realizar a análise de aglomerados. Eles fornecem uma metodologia para explorar e verificar as estruturas presentes nos dados, organizando-os em diferentes grupos ou aglomerados. Essa organização é realizada com base em medidas de similaridades e dissimilaridades (distâncias), de modo a agrupar objetos semelhantes segundo suas características (variáveis) [10] [7].

Neste trabalho foi adotado o algoritmo de K-means como técnica de classificação, o qual particiona um conjunto de dados em K aglomerados. Esses aglomerados são formados com base em alguma medida de similaridade, sendo que o algoritmo ainda utiliza uma técnica de realocação iterativa de modo a encontrar um local ótimo para o aglomerado [7].

Basicamente o algoritmo de K-means define um conjunto de K centróides para os aglomerados. Cada amostra do conjunto de dados é então associada ao aglomerado com centróide mais próximo. Em seguida os centróides são recalculados e a associação das amostras a um aglomerado é refeita. Esse processo é repetido até que os centróides não sejam mais alterados [7].

O critério de agrupamento do K-Means pode ser descrito como sendo

$$E = \sum_{k=1}^K \sum_{x_i \in C_k} d(x_i, x_{0k})$$

onde x_{0k} é o centróide do aglomerado C_k e $d(x_i, x_{0k})$ é a distância entre os pontos x_i e x_{0k} . O centróide pode ser a média ou a mediana de um grupo de pontos. Em outras palavras, o objetivo do K-means é minimizar a distância entre cada ponto e o seu respectivo centróide [12]. Em [7] é encontrada uma explanação mais detalhada sobre o método K-means e sobre a análise de aglomerados.

7. Experimento e Resultados

Visando comprovar e comparar a eficiência da lacunaridade e da dimensão fractal por BoxCounting como métodos de segmentação de textura, foram selecionadas imagens médicas e imagens formadas por texturas de Brodatz para a aplicação dos métodos. A discussão a respeito dos resultados obtidos é apresentada na próxima seção.

A base do algoritmo de segmentação consistiu de uma análise individual de pequenas porções da imagem. Essas porções da imagem foram selecionadas para análise mediante a convolução de uma janela de dimensões $W \times W$ sobre a imagem. Para cada posição desta janela foi realizada a estimativa da lacunaridade ou da dimensão fractal, sendo a curva log-log obtida associada ao pixel da imagem correspondente ao centro da janela. Uma vez computados todos os elementos desta matriz, foi realizada a classificação dos aglomerados através do algoritmo K-means, resultando em uma matriz de rótulos, que representa o mapa de regiões aglomeradas com a mesma textura. O número de classes K adotado no algoritmo de classificação foi estimado visando obter o menor número de regiões diferentes, evitando assim o particionamento excessivo da imagem e o surgimento de regiões similares.

Na Tabela 1 são apresentadas as imagens que foram consideradas no experimento. Nela, observa-se que as duas primeiras imagens são de caráter médico (*a* e *b*) enquanto as outras duas são mosaicos sintéticos formados por texturas de Brodatz (*c* e *d*), freqüentemente utilizadas na literatura como benchmarks para texturas. A escolha em utilizar imagens reais e imagens sintéticas de Brodatz foi feita com o intuito de testar o potencial real dos métodos.

O conjunto de caixas utilizado nos métodos de lacunaridade e dimensão fractal foi escolhido com base

no valor da janela W utilizada no experimento. Sendo assim, iniciava-se o cálculo com uma caixa de largura igual a dois, sendo esse valor incrementado a cada nova iteração do método, até que a largura da caixa atingisse

o valor de W . Dessa maneira evita-se o uso de caixas com largura maior que W , as quais provocariam inconsistências nos resultados.

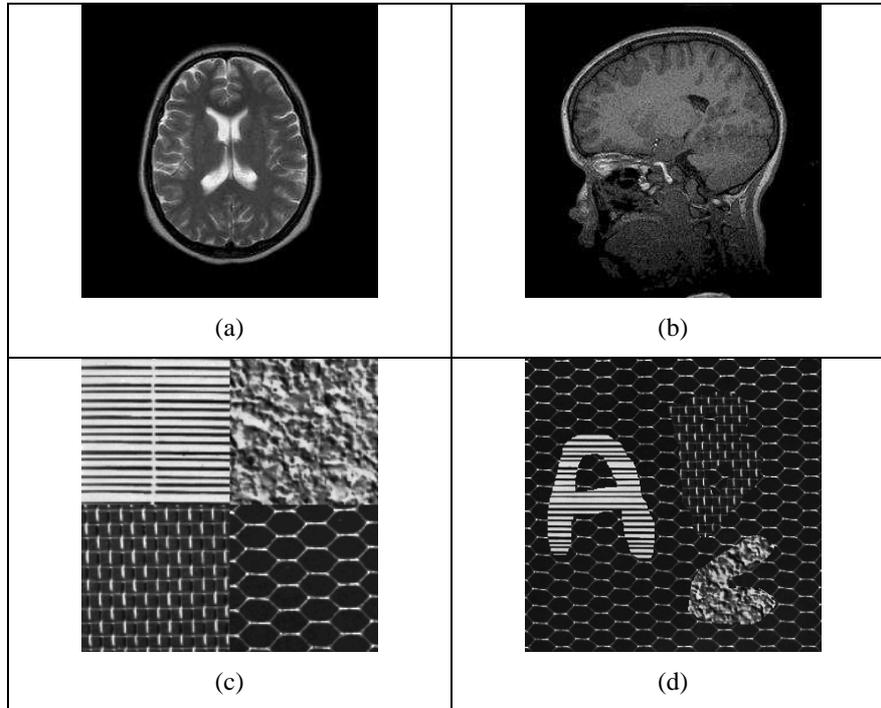


Tabela 1: (a)-(d) Imagens selecionadas para o experimento.

Outro atributo testado se refere ao número de classes K adotado no algoritmo de classificação. Durante a realização dos experimentos percebeu-se que um número muito pequeno de classes produzia a união de classes pouco similares. Por outro lado, o uso de um número alto de classes produziria classes altamente similares entre si.

Os resultados obtidos foram divididos em 4 tabelas: cada tabela agrupou os resultados obtidos para uma das quatro imagens contidas na Tabela 1. Dessa maneira, as Tabelas 2, 3, 4 e 5 correspondem respectivamente aos resultados obtidos para as imagens a, b, c e d, da Tabela 1.

Com base nos resultados é possível perceber como o valor de W varia conforme o tipo de textura

analisada. No caso de imagens formadas por micro-texturas (imagens médicas) foi necessário utilizar um valor pequeno para W . Isso por que as imagens médicas, como as obtidas por meio de Ressonância Magnética, carecem de contornos distintos que separem as diferentes regiões do órgão analisado, neste caso o cérebro. Dessa maneira, a utilização de um valor maior para a janela W provocaria uma maior união de diferentes tipos de texturas numa mesma janela, comprometendo a separação das mesmas em diferentes regiões e, conseqüentemente, produzindo classificações errôneas.

Já com relação à macro-texturas (texturas de Brodatz), o valor de W foi aumentado significativamente, pois o modelo formador desse tipo

de textura necessita de uma janela maior para ser identificado. Dessa maneira, a utilização de um valor menor para a janela W provocaria uma subdivisão do modelo formador da textura, provocando a separação de um padrão de textura em vários e, conseqüentemente, produzindo classificações errôneas. No entanto, valores muito grandes para W devem ser utilizados com cautela, já que podem produzir erros de classificação na faixa onde duas texturas diferentes se encontram.

Com relação aos métodos utilizados, percebe-se um melhor desempenho da dimensão fractal frente a lacunaridade. Isso se deve pelo fato da dimensão fractal ser mais tolerante a pequenas variações na disposição dos pixels que formam a textura, tendo como resultado uma medida do nível de ocupação do espaço, enquanto que a lacunaridade mede a maneira como está preenchido o espaço.

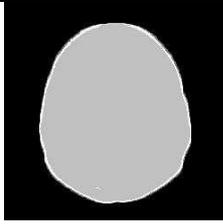
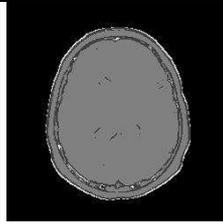
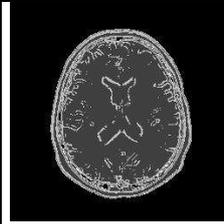
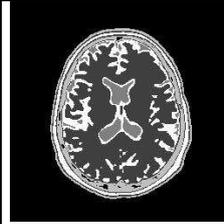
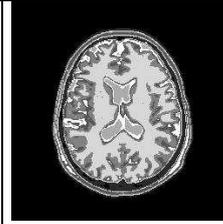
W	10	5	3	3
K	4	4	4	6
Lacunaridade				
Dimensão Fractal				

Tabela 2: resultados do experimento para a imagem (a)

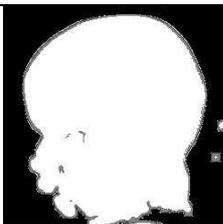
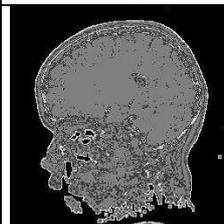
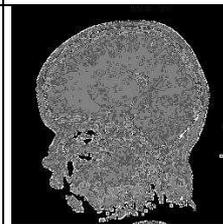
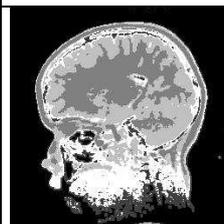
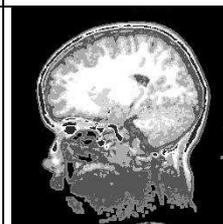
W	10	5	3	3
K	4	4	4	6
Lacunaridade				
Dimensão Fractal				

Tabela 3: resultados do experimento para a imagem (b)

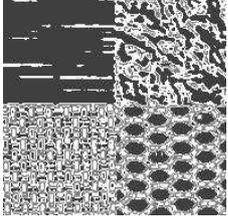
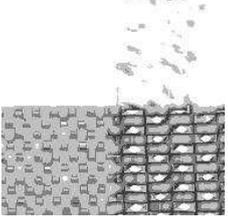
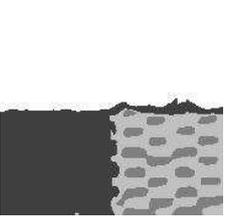
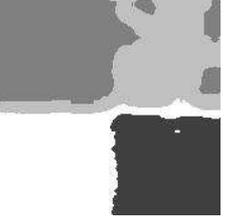
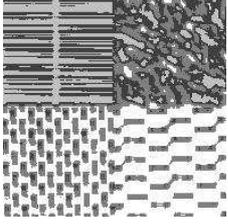
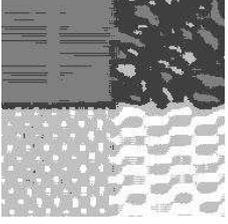
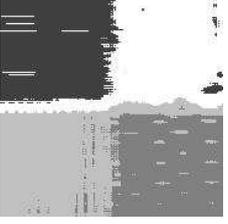
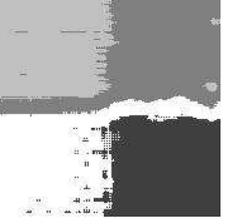
W	5	10	20	25
K	4	4	4	4
Lacunaridade				
Dimensão Fractal				

Tabela 4: resultados do experimento para a imagem (c)

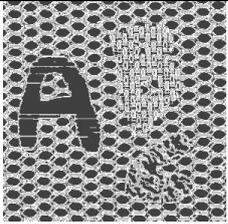
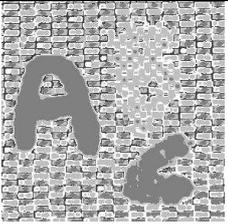
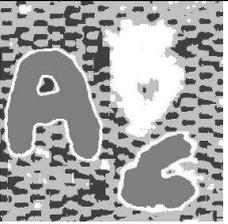
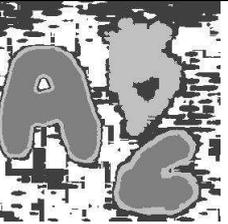
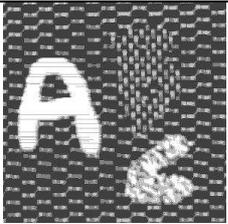
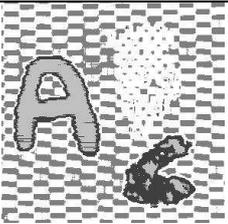
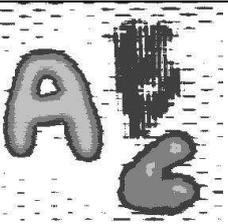
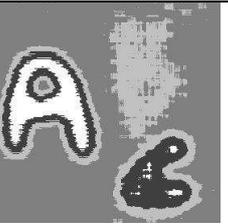
W	5	10	20	25
K	4	4	4	4
Lacunaridade				
Dimensão Fractal				

Tabela 5: resultados do experimento para a imagem (d)

8. Conclusões

Neste trabalho foi apresentado um estudo dos métodos de estimativa da lacunaridade e da dimensão fractal aplicados em análise de textura, mais especificamente para o reconhecimento de padrões e segmentação de textura em imagens digitais.

A partir dos experimentos de segmentação de texturas realizados com os métodos propostos pôde-se constatar que o método baseado na dimensão fractal possui um grande potencial para a análise de textura.

Os resultados obtidos mostraram-se satisfatórios e, apesar do uso de uma técnica menos

elaborada na classificação das assinaturas em aglomerados, demonstram o potencial da técnica na segmentação de texturas reais ou sintéticas (Mosaicos formados com texturas de Brodatz).

Embora esses resultados pudessem ter sido melhorados significativamente por meio do uso de técnicas mais elaboradas de análise, tais como descritores de fourier ou wavelet, e mecanismos mais eficientes de classificação como, por exemplo, redes neurais artificiais, os resultados atenderam ao propósito do trabalho proposto nesse artigo, verificando o potencial da análise de texturas baseada na complexidade da distribuição dos pixels.

9. Bibliografia

- [1] Arivazhagan, S., Ganesan, L. Texture classification using wavelet transform. *Pattern Recognition Letters*, 24(9-10):1513–1521, 2003.
- [2] Allain, C., Cloitre, M. Characterizing the lacunarity of random and deterministic fractals sets, *Phys. Rev. A* 44 (6) 3552. 1991.
- [3] Ângelo, N. P., Haertel, V. Investigação com respeito à aplicação dos filtros de Gabor na classificação supervisionada de imagens digitais, *Anais X SBSR, INPE*, p. 1193-1200, Sessão Técnica Oral. Foz do Iguaçu, 21-26 abril 2001.
- [4] Castleman, K. R. *Digital Image Processing*. Englewood Cliffs, NJ, 1996.
- [5] Chaudhuri, B. B., Sarkar, N. Texture Segmentation Using Fractal Dimension. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, n.17, p. 72-76, 1995.
- [6] Coelho, R. C., Costa, L. da F. The Box-Counting Fractal Dimension: Does it provide an Accurate Subsidy for Experimental Shape Characterization? If So, How to Use It? *Anais do Sibgrapi* 95: p. 183-191, 1995.
- [7] Duda, R., Hart, P., Stork, D. *Pattern Classification*. John Wiley & Sons. 2001.
- [8] Ebert, D.S. *Texturing and Modeling: A Procedural Approach*, Academic Press, Cambridge, MA, 1994.
- [9] Falconer, K.J. *Fractal Geometry: mathematical and applications*. New York, John Wiley, 1990.
- [10] Fred, A. L. N. Finding consistent clusters in data partitions. In J. Kittler & F. Roli (Eds). *MCS '01: Proceedings of the Second International Workshop on multiple Classifier Systems*, Volume 2096 of Lecture Notes in Computer Science, Cambridge, UK, pp. 209-318. 2001.
- [11] Gonzalez, R. C., Woods, R. E. *Digital Imaging Processing*, Addison-Wesley, Reading, Massachusetts, USA, 1992.
- [12] Halkidi, M., Batistakis, Y. & Vazirgiannis, M. On clustering validation techniques. *Intelligent Information Systems Journal* 17(2-3), 107-145. 2001.
- [13] Li, S.Z. *Markov Random Field, Modeling in Computer Vision*, Springer-Verlag, ISBN 0-387-70145-1, 1995.
- [14] Libermann, F. *Classificação de Imagens Digitais por Textura usando Redes Neurais*. Porto Alegre: CPGCC da UFRGS, 86p. Dissertação de Mestrado. 1997.
- [15] Mandal, M. K., Idris, F., Panchanathan, S. A critical evaluation of image and video indexing techniques in the compressed domain. *Image and Vision Computing*, 17:513–529, 1999.
- [16] Plotnick, R.E., Gradner, R.H., Hargrove, W.W., Prestegard, K., Perlmutter, M. Lacunarity analysis: a general technique for the analysis of spatial patterns, *Phys. Rev. E* 53 (5) 5461. 1996
- [17] Tricot, C. *Curves and Fractal Dimension*. New York: Springer-Verlag. 1995.