



O Coeficiente de Hurst e o Coeficiente de Variação Espacial na Segmentação de Texturas Multiespectrais

Éldman de Oliveira Nunes, Aura Conci

Instituto de Computação - UFF, R. Passo da Pátria 156, 24.210-240, Niterói, RJ, Brazil

eldman@pop.com.br, aconci@ic.uff.br

Resumo: *A textura é considerada um descritor regional importante para segmentação e classificação de imagens naturais. Porém, sua caracterização não é uma tarefa fácil. Apesar de sua importância, não existe uma definição rígida para textura. Várias técnicas de segmentação baseadas no emprego de atributos de textura foram propostas, mas diversas dificuldades surgem na quantificação apropriada da textura de uma imagem. Neste trabalho, a caracterização de texturas é apresentada através de duas aproximações: O coeficiente de Hurst (uma aproximação baseado em Dimensão de Fractal) e um novo coeficiente denominado Coeficiente de Variação Espacial, desenvolvido pelos autores. Os resultados experimentais são apresentados e a qualidade da segmentação de texturas obtida com ambas as técnicas são comparadas.*

Palavras-chave: Textura, Segmentação, Dimensão Fractal, Modelos Estatísticos, Coeficiente de Hurst.

Introdução

A textura é uma importante fonte de informações para o processo de análise e interpretação de imagens. A textura refere-se a um padrão visual que possui algumas propriedades de homogeneidade que não resultam simplesmente de uma cor ou intensidade. Ao contrário de outras características, como por exemplo o brilho, a textura não pode ser definida em um pixel, mas sim através de uma região ou conjunto de pixels. Na segmentação baseada em textura, regiões homogêneas da imagem são identificadas levando-se em consideração alguma medida de textura. A análise de textura é uma importante ferramenta para segmentação uma vez que a maioria das imagens naturais possuem um certo perfil textural.

Devido a sua importância, vários métodos empregando modelos estatísticos [15], modelos estruturais [12], modelos morfológicos [18], mapeamentos de frequências [6], modelos fractais [16], redes neurais [21], etc, foram desenvolvidos buscando utilizar a textura como base na segmentação

e descrição de uma imagem. Tais métodos têm sido amplamente utilizados no meio científico e industrial, possuindo aplicações em sensoriamento remoto, medicina, controle de qualidade, recuperação de dados em bases gráficas, dentre outras [19].

Apesar da existência de vários métodos, nenhum deles é capaz de segmentar eficientemente todos os tipos de imagens [17]. Isto por que a caracterização de uma textura não é uma tarefa fácil, especialmente quando mais de uma banda espectral precisa ser considerada [11], caso em que várias dificuldades se sobrepõem à irregularidade de texturas naturais (em brilho, matizes e bordas).

A definição básica de textura (texton) talvez seja a característica mais importante em um método de segmentação. Especialmente quando o texton pode aparecer em resoluções ou escalas diferentes e sua caracterização como um diferencial ou não depende do contexto. Trabalhos recentes apontam para o emprego de técnicas fractais como uma estratégia adequada para lidar com representações em múltiplas escalas [2], [3], [4].

A finalidade deste estudo consiste em descrever e apresentar experimentos e comparar resultados empregando dois métodos para segmentação de imagens digitais por meio de sua textura: o Coeficiente de Hurst [8], baseado em abordagem fractal, e o Coeficiente de Variação Espacial (CVE), proposto neste trabalho e baseado em abordagem estatística.

Textura

Um fator de grande importância na análise de imagens é o reconhecimento de texturas. Este processo sofisticado, realizado intuitivamente pela visão humana, se reveste de grande complexidade computacional [12]. Presente na maioria das imagens naturais a textura é fundamental para visão humana e serve como excelente descritor regional contribuindo, em muitos casos, na melhoria da exatidão do processo de reconhecimento, descrição e classificação de imagens.

A textura é uma expressão relacionada com as propriedades que representam a superfície de um

objeto. É um termo intuitivo e de largo emprego, mas apesar de sua importância, não pode ter uma definição precisa [6]. Segundo Sklansky [17], “uma região em uma imagem apresenta uma textura única se um conjunto de características estatísticas ou outras propriedades locais da imagem forem constantes, com pouca variação ou aproximadamente periódicas”. Para Sonka [19], textura pode ser definida como algo que consiste de elementos mutuamente relacionados (a primitiva de textura, que pode ser um pixel ou um conjunto de pixels). McGrogan [10] define textura como uma estrutura composta de um grande número de elementos similares mais ou menos ordenados. Haralick et al. [7] definiram textura através do uso de coeficientes de uniformidade, densidade, aspereza, regularidade, intensidade, entre outras características da imagem. Estes os autores caracterizam textura como um conceito bidimensional, onde uma dimensão contém as propriedades primitivas da tonalidade e a outra corresponde aos relacionamentos espaciais entre elas. Gonzalez et al. [6] conceituam textura como um descritor que fornece medidas de propriedades como suavidade, rugosidade e regularidade.

Textura, pode ser definida também como uma propriedade de uma região que descreve o padrão de variação de tons de cinza e cor numa determinada área. A textura se caracteriza pela repetição de um modelo (textons) sobre uma região. Este modelo pode ser repetido de forma exata ou com pequenas variações sobre um mesmo tema. Tamanho, formato, cor e orientação dos elementos do modelo podem variar sobre as regiões. A variação encontrada na forma como os “textons” se relacionam é suficiente para diferenciar duas texturas. Uma região precisa possuir um tamanho grande o suficiente para exibir sua textura. Assim, este tamanho não pode ser pequeno se comparado com um “texton”.

Cada autor apresenta sua definição, não existe uma definição única e precisa, nem uma aproximação matemática formal para a quantificação da textura. No entanto, todas as definições estão associadas à impressão de rugosidade e contraste criada pela variação tonal ou pela repetição de padrões visuais sobre uma região. As três principais abordagens usadas para a descrição de texturas são a estatística, a estrutural e a espectral. Na abordagem estatística a textura é definida por um conjunto de medidas locais extraídas do padrão. A abordagem estrutural utiliza a idéia de que texturas são compostas de primitivas dispostas de forma aproximadamente regular e repetitiva, de acordo com regras bem definidas. A abordagem espectral baseia-se em propriedades do espectro de Fourier, sendo principalmente utilizadas na detecção de periodicidade global, através da identificação de picos de alta energia no espectro da imagem.

Existem outras abordagens, as que usam a Geometria Fractal, por exemplo, quantificam a textura a partir de propriedades principais dos objetos fractais: a auto-semelhança, a dimensão fractal e a lacunaridade [9]. A auto-semelhança é uma característica que os objetos fractais possuem de cada pequena porção sua poder ser vista como uma réplica reduzida do todo. A dimensão fractal é uma medida que quantifica a densidade dos fractais no espaço métrico em que são definidos e serve para compará-los. E a lacunaridade é um termo para descrever as características de fractais com mesma dimensão e com aparências diferentes. Segundo Parker [12], a geometria fractal destaca-se dentre as diversas abordagens possíveis para análise textural. Sua utilização para caracterização de texturas é uma área nova e promissora, pois permite identificar e classificar texturas com grande simplicidade e eficiência.

A dimensão fractal é amplamente utilizada para determinação da rugosidade da superfície terrestre, na classificação de imagens, na distinção entre tipos de paisagens, na detecção de bandas espectrais ruidosas, na determinação da escala operacional de fenômenos naturais em imagens digitais, na análise da diversidade da paisagem, na análise dos efeitos da conversão de dados em sistemas de informações geográficas, no escalonamento aplicado às extensões espaciais em sensoriamento remoto, na análise de superfícies fraturadas, desgaste e erosão, corrosão, dentre outros.

Coeficiente de Hurst

Existem na literatura diversos métodos para estimar a dimensão fractal (DF). Pentland [14] sugeriu um método de calcular DF usando transformadas de Fourier do espectro de superfície de intensidade cromática da imagem. Peleg et al [13] foram os primeiros que estenderam a idéia de Mandelbrot [9] considerando uma imagem como uma superfície de terreno cuja altura é proporcional ao valor do nível de cinza. Voss [20] associou o nível de cinza a probabilidade e a contagem de "caixas" com o processo de calcular a probabilidade. Sarkar e Chaudhuri [16] descreveram uma aproximação eficiente denominado Diferencial Box-Counting (DBC), que computa as diferenças e dá resultados satisfatórios em todo o alcance de DF. Embora o método de DBC dê uma estimativa muito boa da DF, Conci e Proença [3] propuseram algumas simplificações computacionais e melhorias no tempo de cálculo. Em Fernandes e Conci (2004) a lacunaridade, outra medida fractal muito importante, é também usada para caracterizar as texturas. Alguns autores como Parker [12] usaram coeficiente de Hurst

como uma aproximação da dimensão fractal para imagens em níveis de cinzas.

O coeficiente de Hurst é uma aproximação da DF, definido como:

$$D = \frac{\ln N}{\ln\left(\frac{1}{r}\right)} \quad (1)$$

Sendo usado no cálculo a intensidade de um conjunto de pixels de uma imagem I dividida em N partes idênticas não coincidentes e escalonadas por um fator de escala de r . Para exemplificar o cálculo do coeficiente de Hurst considere a Fig. 1, que ilustra uma região de 7×7 pixels com seus níveis de intensidade.

	0	1	2	3	4	5	6
0	85	70	86	92	60	102	202
1	91	81	98	113	86	119	189
2	96	86	102	107	74	107	194
3	101	91	113	107	83	118	198
4	99	68	107	107	76	108	194
5	107	94	93	115	83	115	198
6	94	98	98	107	81	115	194

Figura 1: Região de 7×7 pixels para cálculo do coeficiente de Hurst

A figura 2 representa a distância euclidiana de cada pixel em relação ao pixel central, calculadas por meio da Eq. (2). Para este textons de 7×7 , existem oito grupos de pixels, correspondendo às oito diferentes distâncias possíveis.

$$d(x_c, y_c; x_i, y_i) = \sqrt{(x_c - x_i)^2 + (y_c - y_i)^2} \quad (2)$$

O primeiro passo no cálculo do coeficiente de Hurst é determinar a maior diferença de nível de cinza (Δg) para cada classe de distância dos pixels. Neste exemplo, começando com os pixels distantes um ou menos do centro, o nível máximo é 113 e o mínimo é 83, ocorrendo uma diferença de 30. A próxima classe (distância= $\sqrt{2}$) tem o nível mínimo de 74, permanecendo o nível máximo em 113, portanto, uma diferença igual a 39. A terceira classe (distância= 2) possui nível máximo igual a 118 e com nível mínimo permanecendo em 74, logo, uma diferença de nível de intensidade igual a 44. Este processo deve ser

realizado sucessivamente para as oito classes de distâncias.

$\sqrt{18}$	$\sqrt{13}$	$\sqrt{10}$	3	$\sqrt{10}$	$\sqrt{13}$	$\sqrt{18}$
$\sqrt{13}$	$\sqrt{8}$	$\sqrt{5}$	2	$\sqrt{5}$	$\sqrt{8}$	$\sqrt{13}$
$\sqrt{10}$	$\sqrt{5}$	$\sqrt{2}$	1	$\sqrt{2}$	$\sqrt{5}$	$\sqrt{10}$
3	2	1	0	1	2	3
$\sqrt{10}$	$\sqrt{5}$	$\sqrt{2}$	1	$\sqrt{2}$	$\sqrt{5}$	$\sqrt{10}$
$\sqrt{13}$	$\sqrt{8}$	$\sqrt{5}$	2	$\sqrt{5}$	$\sqrt{8}$	$\sqrt{13}$
$\sqrt{18}$	$\sqrt{13}$	$\sqrt{10}$	3	$\sqrt{10}$	$\sqrt{13}$	$\sqrt{18}$

Figura 2: Oito grupos de pixels correspondentes às distâncias

Em seguida, devemos obter o logaritmo das distâncias e das diferenças de nível de cinza, conforme descrito na Tab. 1. De posse destes dados, é possível plotar os pontos definidos pelo logaritmo das distâncias e pelo logaritmo das diferenças de nível de cinza num gráfico conhecido na literatura como gráfico de Richardson.

Tabela 1: Distância e diferença de nível de cinza para região da figura n

Dist (d)	$\ln d$	Diferença de nível de cinza (Δg)	$\ln \Delta g$
$d = 1$	0.000	113-83=30	3.401
$d = \sqrt{2}$	0.346	113-74=39	3.663
$d = 2$	0.693	118-74=44	3.784
$d = \sqrt{5}$	0.804	118-68=50	3.912
$d = \sqrt{8}$	1.039	119-68=51	3.931
$d = 3$	1.098	198-68=130	4.867
$d = \sqrt{10}$	1.151	198-60=138	4.297
$d = \sqrt{13}$	1.282	198-60=138	4.297
$d = \sqrt{18}$	1.445	202-60=142	4.955

O próximo passo consiste em realizar o ajuste da reta ($Y = bx+a$) definida pelos pontos de coordenadas ($\ln d$; $\ln \Delta g$). Através do método dos mínimos quadrados se calcula os parâmetros "b" e "a", Eq. (3) e Eq. (4), da reta que minimiza as distâncias ou diferenças entre Y e Y' . Esta reta é chamada de curva de regressão. A Tabela 2 apresenta os dados utilizados para o cálculo dos parâmetros "a" e "b".

$$b = \frac{n \sum \ln d \ln \Delta g - \sum \ln d \sum \ln \Delta g}{n \sum (\ln d)^2 - (\sum \ln d)^2} \quad (3)$$

$$a = \frac{\sum \ln \Delta g}{n} - b \frac{\sum \ln d}{n} \quad (4)$$

Tabela 2: Dados para cálculo da curva de regressão

n	ln d	ln Δg	ln d ln Δg	(ln d) ²
1	0,00000	3,40120	0,00000	0,00000
2	0,34657	3,66356	1,26969	0,12011
3	0,69315	3,78419	2,62300	0,48045
4	0,80472	3,91202	3,14808	0,64757
5	1,03972	3,93183	4,08800	1,08102
6	1,09861	4,86753	5,34753	1,20695
7	1,15129	4,92725	5,67271	1,32547
8	1,28247	4,92725	6,31908	1,64474
9	1,44519	4,95583	7,16209	2,08856
Σ	7,86173	38,37067	35,63019	8,59489
Σ/n	0,874	4,263		
n	9			

A linha neste caso tem a equação : $Y = 1.2229x + 3.1952$. O declive desta linha, $b=1.2229$, é o coeficiente de Hurst. A Figura 3 representa a imagem original e a Figura 4 a imagem original após o seu processamento com o coeficiente de Hurst.



Figura 3: Imagem Original

Se visualizarmos uma imagem como um mapa de relevo tridimensional, onde a intensidade é vista como a altura sobre um plano x-y, a aplicação do coeficiente de Hurst torna-se particularmente útil para determinar o “gapness” relativo de regiões de imagem diferentes[8].



Figura 4: Coeficiente de Hurst

Coeficiente de Variação Espacial

As medidas de posição ou de tendência central constituem uma forma mais sintética de apresentar os resultados contidos nos dados observados, pois representam um valor central, em torno do qual os dados se concentram. As medidas de posição mais empregadas são a média, a mediana e a moda.

A média, Eq.(5), é a mais usada das três medidas de posição mencionadas, por ser a mais comum e compreensível delas, bem como pela relativa simplicidade do seu cálculo, além de prestar-se bem ao tratamento algébrico.

$$\bar{x} = \frac{\sum_{i=1}^n xi}{n} \quad (5)$$

A mediana para um conjunto de dados ordenados é o valor que divide ao meio o conjunto de tal forma que 50% dos dados é superior a mediana e 50% inferior. A moda de um conjunto de dados é o valor que ocorre com maior frequência, ou seja, o valor mais comum. Para um conjunto de dados a moda pode não ser única ou pode até mesmo não existir.

A utilização de uma medida de posição para substituir um conjunto de dados é insuficiente para sintetizar a informação nele contida, como no seguinte exemplo:

A = 10, 10, 10, 10, 10, 10, 10
 B = 1, 8, 10, 10, 11, 12, 18
 C = 1, 2, 10, 10, 10, 13, 24

Calculando a média, mediana e moda desses três conjuntos obtêm-se:

Media A= Media B = Media C = 10 unidades
 Mediana A= Mediana B=Mediana C= 10 unidades
 Moda A= Moda B = Moda C = 10 unidades

Assim, verifica-se que os três conjuntos (A, B e C) apresentam médias, medianas e modas iguais a 10 unidades, apesar de serem três conjuntos bem diferentes entre si, pois enquanto no conjunto A os dados são todos iguais, os demais apresentam uma certa variação, sendo que esta variação é maior no conjunto C. Portanto, para sintetizarmos eficientemente a informação de um conjunto de dados é necessário associar uma medida de posição a uma medida de dispersão, que vai informar como estes dados se comportam em torno da medida de posição empregada.

A dispersão de um conjunto de dados, Eq.(6), pode ser obtida considerando-se os desvios de cada observação em relação a média (chamados erros) :

$$e = x_i - \bar{x} \quad (6)$$

Para obter um único número que represente a dispersão dos dados utiliza-se a variância, Eq.(7), que é a soma dos quadrados dos desvios dividido pelo número de observações. A variância é uma medida quantitativa da dispersão de um conjunto de dados ao redor da sua média.

$$V(x) = \frac{\sum_{i=1}^n x_i^2}{n} - \left(\frac{\sum_{i=1}^n x_i}{n}\right)^2 \quad (7)$$

Um inconveniente da variância é que ela é expressa em unidades ao quadrado o que causa algumas dificuldades de interpretação. No intuito de resolver este problema trabalha-se com o desvio padrão, Eq.(8).

$$DP = \sqrt{V(x)} \quad (8)$$

A variância e o desvio padrão são medidas de dispersão absolutas, deste modo somente podem ser utilizadas para comparar a variabilidade de dois ou mais conjuntos de dados quando estes apresentarem a mesma média, o mesmo número de observações e estiverem expressos nas mesmas unidades. Então para comparar qualquer conjunto de dados quanto à sua variabilidade deve-se utilizar uma medida de dispersão relativa como o coeficiente de variação, Eq.(9), que expressa a variabilidade dos dados em relação à sua média.

$$CV = \frac{DP}{\bar{x}} 100 \quad (9)$$

O coeficiente proposto neste trabalho quantifica a característica de textura através de medidas estatísticas que descrevem as variações espaciais de intensidade ou cor. Duas medidas são empregadas: uma medida de posição (média) e uma medida de dispersão (coeficiente de variação) do conjunto de

pixels pertencentes à região da imagem. Entretanto, conforme Gonzalez [6] as medidas de textura calculadas apenas com base em seu histograma sofrem a limitação de não carregarem informação sobre a posição relativa dos pixels em relação uns aos outros. Como vimos na seção 2 a textura possui duas propriedades: a tonalidade dos pixels e os relacionamentos espaciais entre eles. O cálculo do CVE leva em consideração não apenas a distribuição de intensidades, mas também sua distribuição espacial pelas classes de distâncias. O primeiro passo no cálculo do Coeficiente de Variação Espacial (CVE) é determinar o conjunto de dados de cada classe de distâncias considerando a distância euclidiana de cada pixel ao pixel central (Fig. 2). Após obter-se a média e o coeficiente de variação para cada classe de distâncias, as medidas de posição e de dispersão são combinadas através da Eq.10, cujo valor único (CVE, da classe) preserva inequivocamente a informação de ambas as medidas obtidas.

$$CVE = \frac{ArcTang\left(\frac{\bar{x}}{CV}\right)Pi}{180} \sqrt{\bar{X}^2 + CV^2} \quad (10)$$

O segundo passo consiste em obter a média e o coeficiente de variação para os CVE de cada classe de distância. Finalmente, a média e o coeficiente de variação dos CVE de cada classe são novamente combinados pela Eq. 10 resultando no CVE da região de textura. A Tabela 3 apresenta a média e o coeficiente de variação e o CVE para os dados da Fig.1.

Tabela 3: Dados para cálculo do CVE

D	MEDIA Classe	CV Classe	CVE Classe	MEDIA CVE classe	CV CVE classe	CVE Textura
1,000	102,500	11,241	150,709	154,522	12,605	230,910
1,414	89,750	16,571	126,698			
2,000	109,250	9,781	162,502			
2,236	91,125	13,667	131,022			
2,828	102,250	15,173	147,145			
3,000	124,500	34,353	168,101			
3,162	113,500	42,245	147,082			
3,606	121,250	35,921	162,219			
4,243	143,750	37,855	195,223			

Experimentos

A fim de verificar o desempenho dos coeficientes na discriminação de texturas coloridas foram realizadas testes com imagens artificiais e naturais.

As Figuras 5 a 9 representam imagens com os valores da intensidade do pixels correspondente a cada classe de distância (através das cores). A Figura

6 corresponde a Figura 5 girada de 90° no sentido horário. Tanto o Coeficiente de Hurst como o CVE possuem valores invariáveis à rotação.

85	70	86	92	60	102	202
91	81	98	113	86	119	189
96	86	102	107	74	107	194
101	91	113	107	83	118	198
99	68	107	107	76	108	194
107	94	93	115	83	115	198
94	98	98	107	81	115	194

Figura 5: Imagem Original: CH=1,222 e CVE=230,910

94	91	96	101	86	70	85
107	94	86	91	98	81	102
99	68	107	113	102	86	60
107	115	107	107	107	113	92
98	93	76	83	74	107	194
98	115	83	118	108	119	189
194	115	81	198	194	198	202

Figura 6: Imagem a 90°: CH= 1,222 e CVE= 230,910

As Figuras 7 e 8 correspondem a linhas horizontais (brancas e pretas) e verticais (brancas e pretas) respectivamente. Para ambos os coeficientes o resultado é invariável, embora o Coeficiente de Hurst tenha obtido valor igual a zero.

255	255	255	255	255	255	255
0	0	0	0	0	0	0
255	255	255	255	255	255	255
0	0	0	0	0	0	0
255	255	255	255	255	255	255
0	0	0	0	0	0	0
255	255	255	255	255	255	255

Figura 7: Linhas Horizontais: CH= 0,000 e CVE=68,359

A Figura 8 corresponde a linhas diagonais (brancas e pretas), como um tabuleiro de xadrez. A Figura 9 corresponde a uma imagem totalmente branca. Para ambas os coeficientes o resultado é igual a zero.

255	0	255	0	255	0	255
0	255	0	255	0	255	0
255	0	255	0	255	0	255
0	255	0	255	0	255	0
255	0	255	0	255	0	255
0	255	0	255	0	255	0
255	0	255	0	255	0	255

Figura 8: Linhas Diagonais
CH= 0,000
CVE= 0,000

255	255	255	255	255	255	255
255	255	255	255	255	255	255
255	255	255	255	255	255	255
255	255	255	255	255	255	255
255	255	255	255	255	255	255
255	255	255	255	255	255	255
255	255	255	255	255	255	255

Figura 9: Valores Iguais
CH= 0,000
CVE= 0,000

Tendo em vista que a Figura 9 é constituída por valores de pixels iguais, a dispersão é nula e o CVE retrata perfeitamente esta característica. Já na Figura 8 a dispersão é máxima e o valor do CVE também foi nulo. Isto ocorreu devido as classes estarem definidas pela distância euclidiana. Se todavia utilizarmos outra medida de distância, como a distância Manhattan, por exemplo, este problema poderá ser facilmente corrigido.

A Figura 10 apresenta um mosaico de texturas de cenas naturais extraídas de imagens de satélite. Cada textura que compõe o mosaico possui 32x32 pixels e demonstram a complexidade de variação tonal existente. As Figuras 11 e 12 apresentam o resultado da segmentação de quatro classes de texturas utilizando o coeficiente de Hurst e o Coeficiente de Variação Espacial, respectivamente. Foram extraídas vinte amostras de cada classe com janela de 5x5 pixels para servir de conjunto de treinamento.

Percebe-se, a partir da Fig.10 que o Coeficiente de Hurst não permitiu distinguir eficientemente as diferentes classes de texturas presentes na imagem. Isto resulta da variação existente do valor do coeficiente para as amostras de uma determinada classe sobrepor-se ao valor da variação das amostras de outra classe.

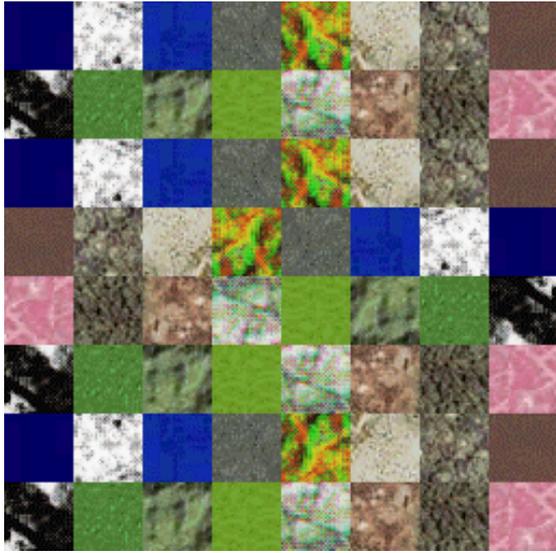


Figura 10: Imagem Original

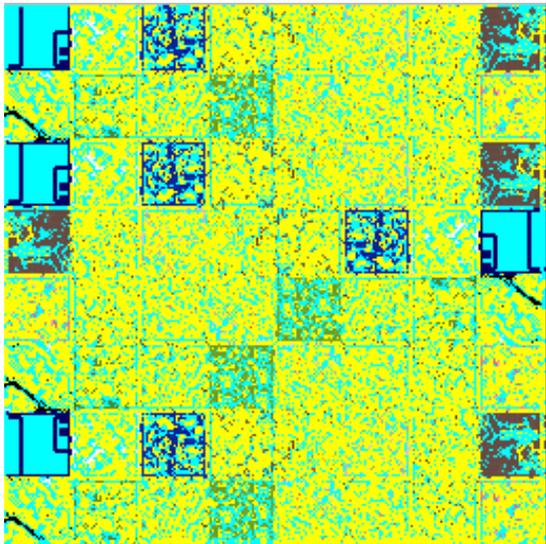


Figura 11: Segmentação com Coeficiente de Hurst

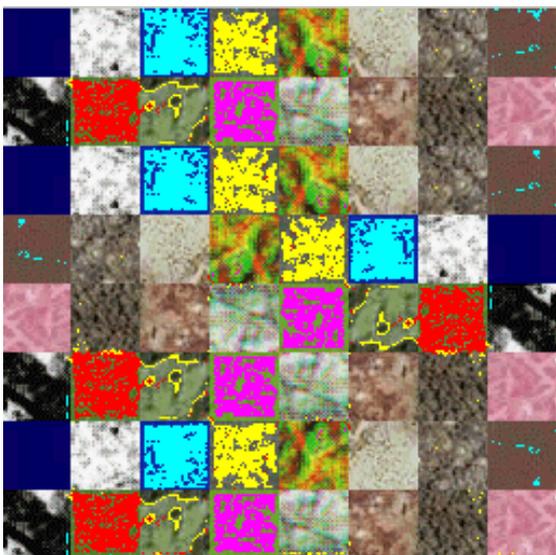


Figura 12: Segmentação com CVE

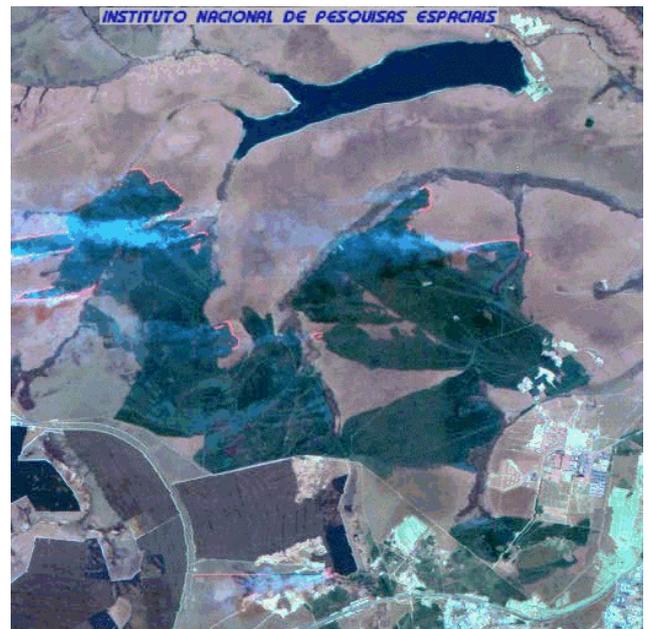


Figura 13: Imagem real

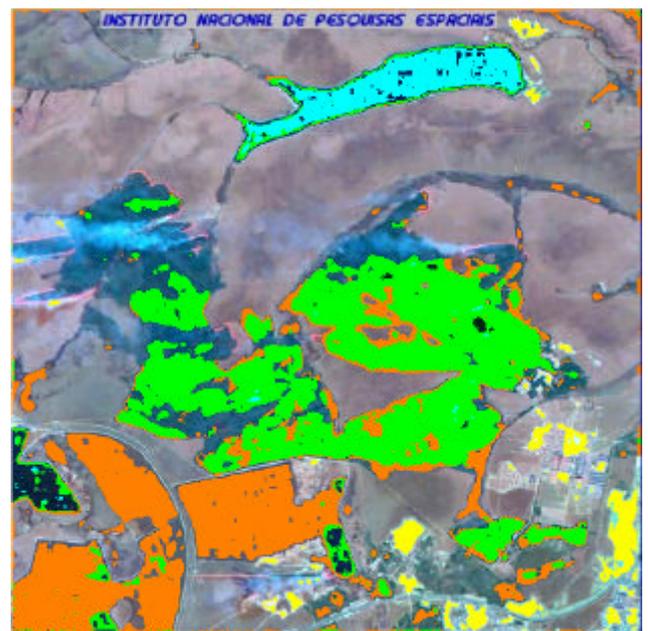


Figura 14: Segmentação com CVE

Percebe-se, a partir da Fig.12 que o Coeficiente de Variação Espacial permitiu distinguir de modo satisfatório as diferentes classes de texturas presentes na imagem da Fig.10. Isto resulta da variação existente do valor do coeficiente para as amostras de uma determinada classe não sobrepor-se ao valor da variação das amostras de outra classe.

A Figura 13 apresenta uma imagem real de satélite e a Figura 14 mostra o resultado da segmentação de quatro classes de texturas (água-ciano, mata-verde, terra arada-laranja, cidade-amarelo) utilizando o Coeficiente de Variação Espacial proposto.

Conclusões

A cor, a textura e a forma são as características da imagem mais utilizadas no reconhecimento de padrões. Uma boa caracterização destas permite identificar padrões ou realizar descrições sobre o conteúdo da imagem. A textura refere-se a um padrão visual que possui propriedades de homogeneidade que não resultam simplesmente de uma cor ou intensidade. A extração de suas características é considerada uma importante fonte de informação para segmentação de imagens.

O coeficiente de Hurst é uma aproximação da dimensão fractal para determinar de forma útil a diferença relativa entre regiões de imagens (tons de cinza), conforme demonstrado na Fig. 3. Entretanto, não apresentou um bom resultado quando empregado na segmentação de texturas coloridas. O Coeficiente de Variação Espacial, aqui proposto, apresentou bons resultados na segmentação de imagens coloridas permitindo distinguir satisfatoriamente diferentes classes de texturas. Muitas técnicas para extração das características de textura envolvem muito esforço computacional e produzem diversas medidas para caracterização da textura. O Coeficiente de Variação Espacial, devido a sua simplicidade e eficiência, constitui-se numa ferramenta útil para segmentação de texturas multiespectrais.

Agradecimentos

O segundo autor agradece ao CNPq, que parcialmente deu suporte a esse trabalho.

Referências

- [1] Bettinger, P., Bradshaw, G. A., Weaver, G. W., "Effects of geographic information system vector-raster-vector data conversion on landscape indices". *Canadian Journal of Forest Research*, 26(8):1416-1425, 1996.
- [2] Chen, K. S., Yen, S. K., Tsay, D. W., "Neural classification of SPOT imagery through integration of intensity and fractal information". *International Journal of Remote Sensing*, 18(4):763-783, 1997.
- [3] Conci, A., Proenca, C.B., "A fractal image analysis system for fabric inspection based on a box-counting method", *Computer Networks and ISDN Systems*, Elsevier Science, 30(20-21), 1887--1985, 1998. <http://www.caa.uff.br/~cproenca/pp.html> e <http://www.caa.uff.br/~aconci>
- [4] Emerson, C. W., Lam, N. S., Quattrochi, D. A., "Multi-Scale fractal analysis of image texture and pattern". *Photogrammetric Engineering & Remote Sensing*, 65(1):51-61, 1999.
- [5] Fernandes, J.L., Conci, A., "A Lacunaridade na Caracterização Espacial de Padrões", *anais do III Congresso Temático de Dinâmica e Controle da SBMAC, Dincon-2004, UNESP/Campus de Ilha Solteira*, 1432--1492, 2004.
- [6] Gonzalez, R.C.; Woods, R.E., "Processamento de Imagens Digitais". Edgard Blucher, São Paulo, Brasil, 2000.
- [7] Haralick, R.M.; Shanmugan, K.; Dinstein, I., "Texture Features for Image Classification". *IEEE Transaction on Systems, Man and Cybernetics*, SMC-3(6):610-621, 1973.
- [8] Hurst, H.E., Black, R.P., Simaika, Y.M., "Long-term storage: an experimental study". Constable, London, 1965.
- [9] Mandelbrot, B.B., "The Fractal Geometry of Nature". San Francisco, 1982.
- [10] McGrogan, N., "Texture segmentation and change detection for urban planning", 1997. <http://www.new.ox.ac.uk/~nmcgrogan/work/ecsproj4/report.html>.
- [11] Olsen, E. R., Ramsey, R. D., Winn, D. S., "A modified fractal dimension as a measure of landscape diversity". *Photogrammetric Engineering & Remote Sensing*, 59(10):1517--1520, 1993.
- [12] Parker, J. R., "Algorithms for Image Processing and Computer Vision". John Wiley & Sons, Toronto, 1997.
- [13] Peleg, S., Naor, J., Hartley, R., Avnir, D.: "Multiple resolution texture analysis and classification", *IEEE Trans Pattern Anal. Machine Intell.*, 6, 518--523, 1984.
- [14] Pentland, A. P., "Fractal based description of natural scenes", *IEEE Trans. Pattern Analysis Machine Intell.*, 6, 661-674, 1984.
- [15] Russ, J. C., "The image processing handbook". New York: CRC Press, 1995.
- [16] Sarkar, N., Chaudhuri, B. B., "An efficient differential box-counting approach to compute fractal dimension of image", *IEEE Trans. on Systems. Man and Cyber.*, 24(1), 115--120, 1994.

- [17]Sklansky, J., "Image Segmentation and Feature Extraction". IEEE Transactions on Systems, Man, and Cybernetics, 13(5), 907--916, 1978.
- [18]Soille, P., "Morphological Image Analysis: Principles and Applications". Springer, Berlin, 1999.
- [19]Sonka, M.; Hlavac, V.; Boyle, R., "Image Processing, Analysis and Machine Vision". London: Chapman & Hall, 1993.
- [20]Voss, R., "Random fractals: Characterization and measurement", in Scaling Phenomena in Disordered Systems, R. Pynn and A. Skjeltorp Eds., Plenum, 1986.
- [21]Watt, A., Policarpo, F., "The Computer Image". Addison-Wesley Pub Co (Net), Harlow, England, 1998 .