

Revista Brasileira de Cartografia (2012) N^o 64/4: 503-516
Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto
ISSN: 1808-0936

APRIMORAMENTOS NUMÉRICOS DO MÉTODO DE ANÁLISE DE TEXTURA PELA DIMENSÃO FRACTAL OBTIDA PELO COEFICIENTE DE HURST

Numerical Improvements of the Texture Analysis Method by Fractal Dimension from the Hurst Coefficient

**Osmar Abílio de Carvalho Júnior¹, Nilton Correia da Silva²,
Renato Fontes Guimarães¹, Roberto Arnaldo Trancoso Gomes¹
& Ana Paula Ferreira de Carvalho¹**

¹Universidade de Brasília – UnB
Laboratório de Sistemas de Informações Espaciais - LSIE
{osmarjr, renatofg, robertogomes}@unb.br,

²Centro Universitário de Anápolis (UniEVANGÉLICA)
Departamento de Ciência da Computação
nilton@unievangelica.edu.br

³Instituto Nacional de Colonização e Reforma Agrária (INCRA)
Coordenação Geral de Meio Ambiente e Recurso Naturais
ana.carvalho@incra.org.br

Recebido em 11 Dezembro, 2011/ Aceito em 05 Julho, 2012
Received on December 11, 2011/ Accepted on July 05, 2012

RESUMO

A geometria fractal torna-se uma alternativa a geometria euclidiana para a descrição de formas irregulares, rugosidade e textura de superfícies. A dimensão fractal tem sido utilizada, principalmente, no processamento de imagens médicas e observações microscópicas de morfologia de partículas. O presente trabalho objetiva implementar o algoritmo de detecção de padrão de textura utilizando o coeficiente de Hurst e avaliar o seu emprego em imagens de sensoriamento remoto. Esta abordagem considera uma relação de vizinhança complexa e bastante robusta. O algoritmo consiste em três etapas: (a) cálculo do número de classes de distância; (b) cálculo da amplitude e do desvio padrão para cada classe de distância; e (c) regressão linear entre o logaritmo da distância e o logaritmo da amplitude ou desvio padrão. No presente trabalho são realizados os seguintes aprimoramentos do algoritmo previamente descrito: (a) cálculo do Coeficiente de Hurst para qualquer dimensão de janela móvel, (b) permitir a adoção do desvio padrão como alternativa da amplitude, (c) geração das imagens referentes ao coeficiente linear, além do usual coeficiente angular; e (d) complementação da análise de textura com o emprego do algoritmo “no-maximumsuppression” (NMS) melhorando a delimitação das feições de borda. O método foi aplicado em imagens do sensor TM-Landsat na região Oeste da Bahia. Os resultados demonstram que este método é excelente na detecção de bordas, realçando os limites de plantações e estradas.

Palavras chaves Textura, Fractal, Processamento digital de imagens, Detecção de borda, Extração de feições.

ABSTRACT

Fractal geometry becomes an alternative to Euclidean geometry to describe irregular shapes, roughness and texture surface. The fractal dimension has been used mainly in medical image processing and microscopic observations of morphology from particles. This paper aims to implement an algorithm for the texture detection using the Hurst coefficient, evaluating its use in remote sensing images. This approach considers a very complex and robust neighborhood relationship. The algorithm consists of three steps: (a) calculation of the number of distance classes, (b) calculation of the range and standard deviation for each distance class, and (c) linear regression between the logarithm of the maximum difference and the logarithm of the distance from the central pixel. In this work we made the following improvements of the algorithm previously described: (a) use of variable window size, and (b) use of the standard deviation as an alternative to the amplitude; (c) generation of linear coefficient images (besides the usual slope); and (d) completion of the texture analysis using the “no-maximum suppression” (NMS) algorithm improving the edge detection. The method was applied to Landsat-TM images of Western Bahia region. The results show that the coefficient of Hurst is excellent in detecting edges, highlighting the limits of crops and roads.

Keywords: Texture, Fractal, Digital image processing, Edge detection, Feature extraction.

1. INTRODUÇÃO

As imagens de sensoriamento remoto não apresentam uma variação uniforme de suas intensidades, em vez disso, apresentam uma distribuição que se repete em padrões denominados de textura visual. Estes padrões de textura representam propriedades físicas das superfícies da imagem como rugosidade e orientação ou de variação da refletância (diferenças de cor).

Apesar da ampla utilização do conceito de textura, é difícil produzir uma definição comumente aceita (Zucker & Kant, 1981). Os diferentes níveis de abstração dos sistemas representacionais consistem na base deste problema. Estas estruturas com níveis múltiplos determinam inúmeras possibilidades e diferentes descritores de textura. Desta forma, a textura pode ser percebida em escalas e resoluções diferentes (Gibson, 1950).

No processamento digital de imagem, normalmente, a textura pode ser descrita como uma função da variação espacial. Conforme Hawkins (1969) a textura depende de três características: (i) alguma ordem local que é repetida ao longo de uma região de dimensão maior que o tamanho da ordem, (ii) esta ordem possui um arranjo não aleatório de partes elementares, e (iii) as partes são entidades mais ou menos uniformes com aproximadamente as mesmas dimensões em todos os lugares dentro da região de mesma textura. A mais ampla utilização da textura é o reconhecimento de regiões homogêneas e homólogas, como também, na detecção e extração de feições. Com este propósito, a geometria fractal fornece uma estrutura matemática

diferenciada que permite distinguir o grau de auto-similaridade em diferentes escalas.

O conceito de fractal introduzido por Mandelbrot (1982) fornece uma excelente explicação sobre as superfícies e fenômenos encontrados na natureza. Muitas aplicações da geometria fractal enfocam a simulação gráfica de objetos e feições naturais como árvores, costa litorânea, entre outros. Esta concepção torna-se uma alternativa a geometria euclidiana para a descrição de formas irregulares, possuindo grande potencial na caracterização da rugosidade e textura das superfícies.

As imagens digitais de sensores remotos podem ser consideradas como superfícies espaciais onde a sua complexidade pode ser medida por fractais. Desta forma, a dimensão fractal estabelece um critério para identificar padrões, onde os pixels com valores próximos podem conter propriedades similares e pertencerem a uma mesma classe. O emprego da análise de textura baseado na dimensão fractal tem sido utilizado principalmente no processamento de imagens médicas (Caldwell *et al.* 1990; Caligiuri *et al.* 1994; Chen *et al.*, 1989; Egiaret *et al.* 2002; Li *et al.* 2007; Lundervold, 1992; Vittitoe, 1994; Yaffe, 2008) e microscópicas para análise de grãos (Podsiadlo & Stachowiak, 1998, 1999, Stachowiak, 1998; Stachowiak & Podsiadlo, 1999). Em sensoriamento remoto esta técnica é pouco explorada apesar de possuir um grande potencial de aplicação.

O presente artigo possui como objetivo avaliar e aprimorar a análise de textura baseada na dimensão fractal obtida pelo coeficiente de

Hurst (Hurst, 1951) em imagens de sensoriamento remoto. Esta abordagem considera uma relação de vizinhança complexa e bastante robusta. Para tanto, foi desenvolvido um programa específico para o emprego deste método aprimorando o algoritmo inicialmente proposto por Russ (1990). O método foi aplicado em imagens do sensor TM-Landsat na região do Oeste da Bahia.

2. ÁREA DE ESTUDO

A área de estudo está localizada na região do Oeste da Bahia caracterizada como uma paisagem agrícola com alta dinâmica espacial, devido ao intenso crescimento da agricultura mecanizada (Menke *et al.*, 2009). Esta região apresenta condições favoráveis para o avanço do agronegócio, como: terras planas, alta insolação, estímulo do governo com diversos programas de incentivo e crédito agrícola, e alta precipitação (1600 mm/ano) concentrada nos meses entre Outubro e Março (Kaimowitz and Smith, 2001; Smith *et al.*, 1998). A relativa escassez de água durante o período da seca é suprida por irrigação com a utilização das águas dos tributários do Rio São

Francisco, perenes e de boa vazão, ou do aquífero Urucuaia (Gaspar, 2006), sob forma de poços tubulares profundos.

Na área de estudo existe um profundo conhecimento proveniente de trabalho de campo e informações fornecidas pelos agricultores (Figura 1). Desta forma, é possível estabelecer uma verdade de campo que possa ser comparada com os resultados obtidos pela análise de textura.

As imagens utilizadas são relativas ao sensor TM-Landsat que possui um extenso acervo histórico com ampla utilização no sensoriamento remoto. A imagem utilizada é referente à órbita 220 e ponto 68 do dia 17 de junho de 2006. Os testes realizados consideraram as bandas 1, 2, 3, 4, 5 e 7 pertencentes às faixas do visível e infravermelho.

3. ANÁLISE TEXTURAL UTILIZANDO O COEFICIENTE DE HURST

Russ (1990) desenvolveu um filtro convolucional com dimensão 7x7 que implementa o coeficiente de Hurst, uma aproximação da dimensão fractal. Este coeficiente estabelece uma relação entre o valor de nível de cinza e a sua

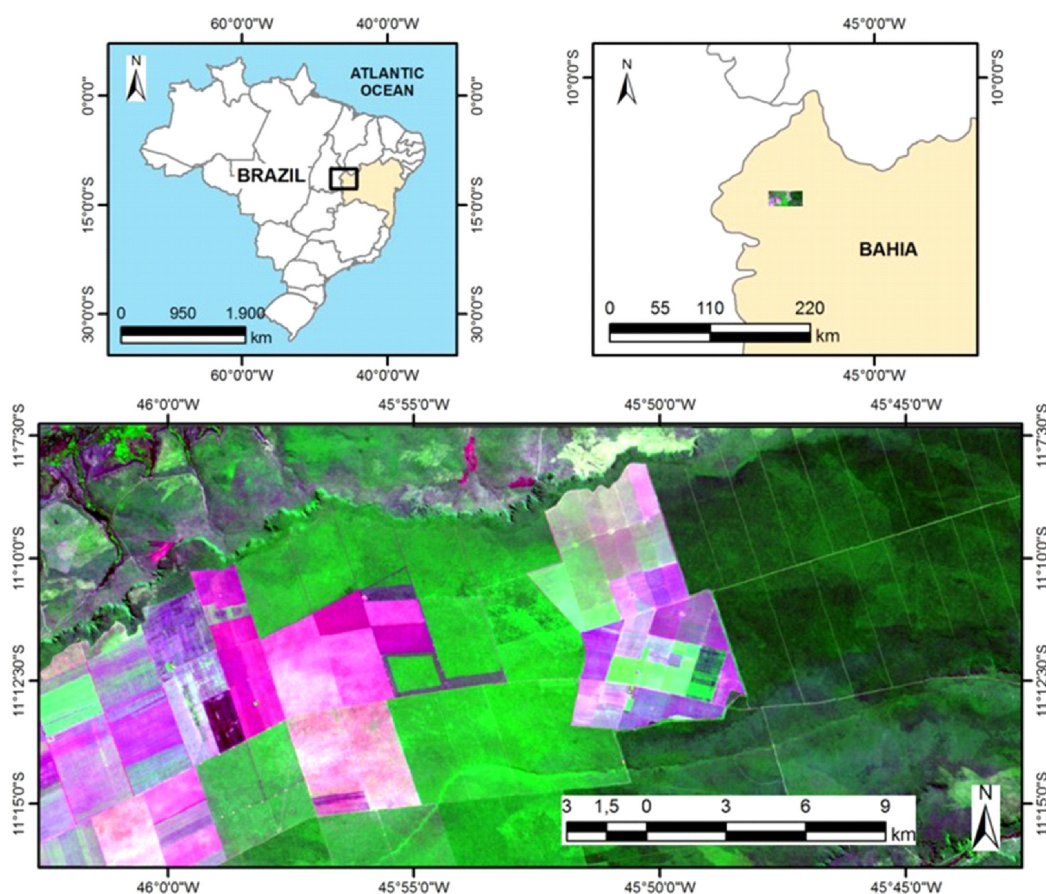


Figura 1 – Área de estudo na região do Oeste da Bahia.

distância ao centro da janela. A partir da distância medida em pixels do eixo x (X) e do eixo y (Y) em relação ao centro é calculada a distância euclidiana (Dist) pela seguinte equação:

$$Dist = \sqrt{X^2 + Y^2} \quad (1)$$

A **Figura 2** demonstra as classes de distância presentes na janela 7x7. Neste modelo elaborado por Russ (1990) é estabelecida uma janela com uma estrutura hexagonal. O conceito básico do modelo fractal é conceber que a variação de níveis de cinza seja correlacionada com a distância espacial entre os pixels. Deve-se salientar que o método considera como dado de entrada uma imagem com 256 níveis de cinza. Independentemente do tipo de imagem a ser adotado, o método realiza inicialmente a conversão dos dados para esta escala de valores.

Para cada classe de distância é estabelecido o valor de amplitude dos níveis de cinza dentro da janela. Por exemplo, a classe com um valor de distância igual a 1 é representada por quatro pixels, onde são determinados os valores máximo e mínimo dos níveis de cinza e, conseqüentemente, o valor de amplitude. Para tanto, pode-se estabelecer uma tabela que contraponha os valores do logaritmo da distância e o logaritmo da amplitude. A partir dessas duas seqüências de valores é estabelecida uma regressão linear por mínimos quadrados sendo calculado o coeficiente linear e angular da reta. O coeficiente de Hurst é representado pelo coeficiente angular, ou seja, a inclinação. A distribuição diferenciada desta relação ao longo da imagem permite a extração das feições.

4. ADEQUAÇÕES ALGORITMICAS PARA O CÁLCULO DO COEFICIENTE DE HURST

Neste trabalho são realizados os seguintes aprimoramentos do algoritmo de Russ (1990): (a) cálculo do Coeficiente de Hurst para qualquer dimensão de janela móvel; (b) permissão da adoção do desvio padrão como alternativa ao valor de amplitude no cálculo do Coeficiente de Hurst; (c) geração das imagens referentes ao coeficiente linear além do usual coeficiente angular; e (d) complementação da análise de textura com o emprego do algoritmo “no-maximum suppression” (NMS) (Canny, 1986) com o propósito de melhorar a delimitação das feições de borda.

		$\sqrt{10}$	3	$\sqrt{10}$		
	$\sqrt{8}$	$\sqrt{5}$	2	$\sqrt{5}$	$\sqrt{8}$	
$\sqrt{10}$	$\sqrt{5}$	$\sqrt{2}$	1	$\sqrt{2}$	$\sqrt{5}$	$\sqrt{10}$
3	2	1		1	2	3
$\sqrt{10}$	$\sqrt{5}$	$\sqrt{2}$	1	$\sqrt{2}$	$\sqrt{5}$	$\sqrt{10}$
	$\sqrt{8}$	$\sqrt{5}$	2	$\sqrt{5}$	$\sqrt{8}$	
		$\sqrt{10}$	3	$\sqrt{10}$		

Figura 2 – Distância de cada pixel da janela ao pixel central considerando uma janela com dimensão de 7 linhas por 7 colunas.

Desta forma, o algoritmo desenvolvido pode ser subdividido nas seguintes etapas: (a) cálculo do número de classes de distância considerando qualquer dimensão de janela; (b) cálculo da amplitude e do desvio padrão para cada classe de distância; (c) regressão linear entre o logaritmo da distância e o logaritmo da amplitude ou, alternativamente, o logaritmo do desvio padrão; e (d) emprego opcional de um algoritmo de NMS. Cada uma das etapas descritas apresenta características próprias que são descritas nos tópicos a seguir.

4.1. Algoritmo para o cálculo do número de classes de distância presentes em uma janela móvel

As classes de distâncias estão dispostas em um arranjo espacial dentro da janela móvel. A **Figura 3** demonstra os padrões de repetições das classes presentes, onde as células demarcadas em vermelho apresentam oito repetições na janela, enquanto que as células em amarelo dispostas ao longo dos eixos e nas diagonais apresentam quatro repetições.

Considerando apenas um dos triângulos formados dentro de um quadrante (áreas com tonalidades de vermelho e amarelo escuro na **Figura 3**), pode-se facilmente adotar um algoritmo para determinar o número de classes presentes em uma janela de qualquer dimensão. Esta análise torna-se

$\sqrt{32}$	$\sqrt{25}$	$\sqrt{20}$	$\sqrt{17}$	4	$\sqrt{17}$	$\sqrt{20}$	$\sqrt{25}$	$\sqrt{32}$
$\sqrt{25}$	$\sqrt{18}$	$\sqrt{15}$	$\sqrt{10}$	3	$\sqrt{10}$	$\sqrt{15}$	$\sqrt{18}$	$\sqrt{25}$
$\sqrt{20}$	$\sqrt{15}$	$\sqrt{8}$	$\sqrt{5}$	2	$\sqrt{5}$	$\sqrt{8}$	$\sqrt{15}$	$\sqrt{20}$
$\sqrt{17}$	$\sqrt{10}$	$\sqrt{5}$	$\sqrt{2}$	1	$\sqrt{2}$	$\sqrt{5}$	$\sqrt{10}$	$\sqrt{17}$
4	3	2	1		1	2	3	4
$\sqrt{17}$	$\sqrt{10}$	$\sqrt{5}$	$\sqrt{2}$	1	$\sqrt{2}$	$\sqrt{5}$	$\sqrt{10}$	$\sqrt{17}$
$\sqrt{20}$	$\sqrt{15}$	$\sqrt{8}$	$\sqrt{5}$	2	$\sqrt{5}$	$\sqrt{8}$	$\sqrt{15}$	$\sqrt{20}$
$\sqrt{25}$	$\sqrt{18}$	$\sqrt{15}$	$\sqrt{10}$	3	$\sqrt{10}$	$\sqrt{15}$	$\sqrt{18}$	$\sqrt{25}$
$\sqrt{32}$	$\sqrt{25}$	$\sqrt{20}$	$\sqrt{17}$	4	$\sqrt{17}$	$\sqrt{20}$	$\sqrt{25}$	$\sqrt{32}$

Figura 3 – Valores de distâncias a partir do centro da janela (9x9). Os eixos principais e as diagonais (amarelo) apresentam quatro repetições, os demais valores (vermelho) repetem oito vezes.

simples por considerar apenas a Metade da Janela (MJ). Considerando que o Tamanho da Janela (TJ) é sempre um número ímpar podemos obter o valor de MJ pela seguinte formulação:

$$MJ = \frac{TJ+1}{2} \quad (2)$$

Assim, para o exemplo dado na **Figura 3** temos que o TJ é igual a 9 e o MJ é igual a 5. O valor de MJ apresenta uma relação com o número de classes como exemplifica a **Tabela 1**. O número de classes pode ser definido facilmente pela somatória dos valores de uma progressão aritmética de 2 até o valor MJ.

Essa relação permite facilmente detectar o número de distâncias existentes para qualquer dimensão de janela. Uma exemplificação do código para o cálculo do número de classe em C++ é demonstrado na **Figura 4**. Eventualmente em janelas de dimensões maiores pode ocorrer a presença de valores de distâncias iguais dentro da faixa triangular demonstrada na **Figura 3**. Neste caso, o algoritmo descrito considera a presença de duas classes distintas, apesar de que teoricamente deveriam ser inclusas em uma única classe. Por ser um evento raro, esta simplificação possibilita maior rapidez no processamento, evitando a busca de classes com valores similares. Além disso, estas eventuais classes de mesma distância não deixam

```

/*
Parte do código para o cálculo
do número de classe
MJ = metade da janela
NClasse = número de classe
*/

int MJ, TJ, i, NClasse;
MJ = (TJ+1)/2;
NClasse = 0;
for(i=1; i<= MJ; i++)
{
    NClasse += i;
}
    
```

Figura 4 – Exemplificação do código em C++ para a definição do número de classes relativas à distância do pixel ao centro da janela.

de ser consideradas. Tornam-se pontos distintos na etapa de regressão linear contribuindo para a determinação do coeficiente de Hurst.

4.2. Algoritmo para o cálculo da amplitude e desvio padrão

Após a definição das classes das distâncias presentes na janela é necessário realizar o cálculo de amplitude dentro de cada classe estabelecida. Desta forma, o algoritmo percorre as colunas e as linhas da janela definindo um conjunto de dados que pode ser esquematizado de uma forma tabular.

Cada classe pode obter um índice específico considerando a distância entre o eixo “x” e o eixo “y” ao centro da janela. Inicialmente define-se qual é o eixo de distância máxima (Dmax) e mínima (Dmin). A aquisição de um índice específico para cada classe é obtida pela soma da distância mínima com o somatório da progressão aritmética entre 1 e a distância máxima. Com o propósito de favorecer os cálculos computacionais, a primeira classe pode iniciar com o valor igual a zero. Para tanto é necessário subtrair o valor da soma por 1 alterando a equação da seguinte forma:

$$IC = Dmin - 1 + \sum_{i=1}^{Dmax} i \quad (3)$$

Onde “IC” é o índice da classe de distância. Os pixels da janela com mesmo índice são comparados para estabelecer os valores de

Tabela 1 - Relação do número de classes de distâncias e a dimensão da janela

Tamanho da Janela (TJ)	Metade da Janela (MJ)	Somatório da Progressão aritmética	Número de classes
3x3	2	2	2
5x5	3	2+3	5
7x7	4	2+3+4	9
9x9	5	2+3+4+5	14

intensidade máxima e mínima. Após a identificação destes valores, realiza-se o cálculo de amplitude ou de desvio padrão. A **Figura 5** mostra os índices das classes de distância considerando uma janela com dimensão 9 x 9.

Os valores relativos à distância e à amplitude (ou desvio padrão) são submetidos a uma função logarítmica.

Como exemplificação, a **Tabela 2** demonstra o cálculo do coeficiente de Hurst a partir de uma janela 9x9 para uma porção de imagem de mesma dimensão, presente na **Figura 6**. Nesta tabela são demonstrados os seguintes valores: índice da classe, distância máxima, distância mínima, distância total, amplitude, desvio padrão e os respectivos logaritmos.

4.3. Regressão linear entre o logaritmo da distância e o logaritmo da amplitude ou desvio padrão

A regressão linear por mínimos quadrados é realizada entre os logaritmos de distância e da amplitude, a partir das diferentes classes. Opcionalmente, a amplitude pode ser substituída pelo desvio padrão. Desta forma, o coeficiente angular (*b*), que representa o coeficiente de Hurst, é obtido pela seguinte formulação:

$$b = \frac{\sum_{i=1}^n \log(Dist_i) * \log(A_i) - \frac{\sum_{i=1}^n Dist_i \sum_{i=1}^n A_i}{n}}{\sum_{i=1}^n Dist_i^2 - \frac{(\sum_{i=1}^n Dist_i)^2}{n}} \quad (4)$$

Onde “*Dist*” é a distância expressa em pixel, “*A*” é a amplitude dos níveis de cinza e “*n*” o número de classes de distância. Complementarmente, pode ser calculado o coeficiente linear “*a*” considerando os valores de média do log (*A*) e log (*Dist*) descrita pela seguinte formulação:

$$a = Média(\log(A)) - b * Média(\log(Dist)) \quad (5)$$

13	12	11	10	9	10	11	12	13
12	8	7	6	5	6	7	8	12
11	7	4	3	2	3	4	7	11
10	6	3	1	0	1	3	6	10
9	5	2	0		0	2	5	9
10	6	3	1	0	1	3	6	10
11	7	4	3	2	3	4	7	11
12	8	7	6	5	6	7	8	12
13	12	11	10	9	10	11	12	13

Figura 5 – Representação da distribuição das classes dentro de uma janela com dimensão 9x9.

250	220	199	198	160	140	107	100	98
214	230	212	180	155	114	111	118	113
210	220	190	133	137	132	150	97	92
200	198	141	150	120	110	138	80	84
185	177	115	123	130	137	122	69	77
100	145	129	141	119	116	67	78	76
107	133	134	100	122	60	70	51	60
96	101	97	89	88	58	45	44	48
97	92	85	86	70	56	41	40	38

Figura 6 – Representação de uma imagem hipotética com dimensão igual a 9 x 9. Para esta imagem é realizado o cálculo do coeficiente de Hurst considerando uma janela de mesma dimensão e demonstrada na **Tabela 2**.

Tabela 2 – Cálculo realizado dentro da janela 9x9 considerando a imagem presente na Figura 6.

Índice da classe (Equação 3)	Distância máxima na Janela	Distância mínima da Janela	Distância (Equação 1)	Valor Máximo	Valor Mínimo	Amplitude	Desvio Padrão	Log Distância	Log Amplitude	Log Desvio Padrão
0	1	0	1	137	119	18	8,341663	0	2,890372	2,121263
1	1	1	1,414214	150	110	40	19,2765	0,346574	3,688879	2,958887
2	2	0	2	137	115	22	9,273618	0,693147	3,091042	2,227174
3	2	1	2,236068	141	60	81	32,77194	0,804719	4,394449	3,489573
4	2	2	2,828427	190	70	120	49,90658	1,039721	4,787492	3,910153
5	3	0	3	177	69	108	51,89332	1,098612	4,682131	3,94919
6	3	1	3,162278	198	58	140	51,37189	1,151293	4,941642	3,939091
7	3	2	3,605551	220	45	175	65,63264	1,282475	5,164786	4,184073
8	3	3	4,242641	230	44	186	77,88613	1,445186	5,225747	4,355248
9	4	0	4	185	70	115	58,13203	1,386294	4,744932	4,062717
10	4	1	4,123106	200	56	144	55,70073	1,416607	4,969813	4,019993
11	4	2	4,472136	210	41	169	61,05486	1,497866	5,129899	4,111773
12	4	3	5	220	40	180	67,67345	1,609438	5,192957	4,214694
13	4	4	5,656854	250	38	212	90,61779	1,732868	5,356586	4,506651

As regressões lineares para os exemplos descritos na Tabela 2 são representados, tanto na Figura 7, considerando a relação entre o logaritmo da distância e o logaritmo da amplitude, como na Figura 8, substituindo o logaritmo da amplitude pelo logaritmo do desvio padrão. Observam-se nos exemplos que os pontos ficaram distribuídos próximos de uma reta permitindo um bom ajuste.

4.4. Emprego do algoritmo “No-Maximum Suppression”

O emprego do coeficiente de Hurst proporciona normalmente a geração de feições duplas ao longo de estruturas lineares e limites de borda. Esta característica de duplicação é observada em outros filtros de detecção de borda, como os filtros relativos à magnitude do método Sobel e a magnitude dos gradientes na direção x e y.

Canny (1986) propôs o emprego de um algoritmo denominado de “no-maximum suppression” (NMS) com o propósito de delimitar o limite de borda e eliminar a feição dupla. O NMS consiste num algoritmo que suprime as feições de vizinhança demarcando apenas o pixel que melhor representa o limite de mudança. O método considera as duas direções preferenciais da janela ao longo dos eixos cartesianos. Para o caso específico da imagem do Coeficiente de Hurst o NMS deve atuar na identificação do valor de mínimo local em relação aos seus vizinhos.




Figura 7 – Relação linear entre o log(distância) versus o log(amplitude) para a janela 9x9 descrita na Figura 6. A inclinação da reta é de 1,479 e representa o coeficiente de Hurst para a janela em análise.




Figura 8 – Relação linear entre o log(distância) versus o log(desvio padrão) para a janela 9x9 descrita na Figura 6. A inclinação da reta é de 1,382 e representa o coeficiente de Hurst para a janela em análise.

Desta forma, como uma complementação do processamento proposto, um algoritmo de NMS foi desenvolvido para as imagens do Coeficiente de Hurst. O método considera sempre uma janela com uma dimensão menor que a utilizada no índice fractal. Desta forma, para uma imagem do Coeficiente de Hurst gerada a partir de uma janela de dimensão 9x9 considera-se o emprego do NMS com uma janela de dimensão 7x7. O método NMS desenvolvido considera as quatro direções preferenciais (**Figura 9**). A definição da existência de um ponto de mínimo é realizada pela relação do ponto central da janela com os pontos mais distantes ao longo de uma direção. No algoritmo proposto além dos pontos extremos são considerados também os valores intermediários entre o pixel central e os de maiores distâncias. Para janelas superiores que 7x7 sempre são avaliados cinco valores. No caso em que o valor da metade da janela (MJ) for um número par o algoritmo considera o ponto intermediário mais próximo do ponto extremo.

O algoritmo somente considera os pontos onde o valor central for menor que os dois pixels intermediários se estes forem menores que os pixels extremos. Para os pixels que respeitarem esta condição efetuam-se as subtrações dos valores dos pixels posicionados nos pontos extremos (PE) com relação ao valor do pixel central (PC) e divide-se por dois, conforme a seguinte equação:

$$indice = \frac{\sum PE - PC}{2} \quad (6)$$

Por fim, um valor de limite de corte pode ser realizado sobre a imagem salientando apenas as feições de borda.

5. RESULTADO

5.1. Imagens do Coeficiente de Hurst

O método foi testado na área de estudo considerando diferentes tamanhos de janela e avaliando as diferenças entre o emprego da amplitude e do desvio padrão. A **Figura 10** apresenta as imagens resultantes do coeficiente de Hurst a partir do cálculo da amplitude considerando as dimensões de janelas de 5x5, 9x9, 13x13 e 15x15 para a banda TM-1 da área de estudo.

Observa-se que existe uma maior delimitação das feições de borda à medida que aumenta a dimensão do filtro. Esta característica salienta a




Figura 9 – As direções preferenciais utilizadas no algoritmo NMS. Os pontos avaliados para a detecção do mínimo local: pixel central (azul), pixels intermediários (amarelo) e pixels extremos (verde).


importância da livre escolha do usuário para estabelecer o tamanho da janela mais apropriada para a imagem em análise. O emprego de um tamanho fixo empobrece a capacidade e o emprego da análise fractal.

Uma das principais características da imagem resultante é a geração de uma borda dupla bem demarcada ao longo das feições lineares e que se intensifica com o aumento da dimensão da janela utilizada.


A **Figura 11** demonstra em detalhe a feição dupla oriunda de uma janela do coeficiente de Hurst com dimensão de 17x17. O traço vermelho da **Figura 11** salienta um perfil horizontal sobre a imagem, onde os valores relativos aos coeficientes de Hurst demonstram o posicionamento do limite da borda como sendo o valor de mínima local situada entre dois valores de máxima local (sinalizadas na figura pelas setas). O mapeamento destas feições de características próprias possibilita demarcar os limites entre as feições.

O emprego do algoritmo NMS aplicado na imagem do Coeficiente de Hurst permite reduzir as feições duplas para uma única feição que melhor delimita os contornos lineares e de borda. A **Figura 12** apresenta as imagens resultantes das seguintes

A - Imagem TM-1



B - Coeficiente de Hurst - janela 5x5



C - Coeficiente de Hurst - janela 9x9



D - Coeficiente de Hurst - janela 13x13



E - Coeficiente de Hurst - janela 17x17



Figura 10 – Imagens do coeficiente de Hurst considerando diferentes dimensões de janela, sendo: (a) imagem original referente à banda 1, (b) imagem resultante da janela 5x5; (c) janela 9x9; (d) janela 13x13; e (e) janela 17x17.

operações: (a) emprego do coeficiente de Hurst com uma janela 17x17; (b) emprego do programa NMS com uma janela de dimensão 15x15; e (c) definição de um valor limite para individualizar as feições de borda.

O algoritmo NMS apresenta uma boa adequação das feições considerando diferentes dimensões de janela. Normalmente os melhores resultados são obtidos quando se adota uma janela com uma dimensão menor que a da janela utilizada pelo coeficiente de Hurst.

5.2. Imagens do coeficiente linear proveniente do cálculo de Hurst

Apesar de não ser explorada a imagem referente ao coeficiente linear da regressão do Cálculo de Hurst, este permite uma eficaz delimitação das feições de borda. Diferentemente do coeficiente angular, não são evidenciadas feições duplas tão pronunciadas ao longo dos lineamentos. Estas imagens se caracterizam pela presença de pixels com elevados valores de intensidade ao longo das bordas, o que facilita a sua delimitação.

A **Figura 13** apresenta as imagens resultantes do coeficiente linear do cálculo de Hurst considerando diferentes dimensões de janela (a) 5x5; (b) 9x9; (c) 13x13; (d) 17x17. Com o aumento da dimensão do filtro observa-se uma delimitação mais acentuada das feições de borda que adquirem uma maior espessura e contraste com o fundo da imagem.

Normalmente, as áreas de maior intensidade são bordejadas por zonas com menores valores apresentando uma situação inversa ao do coeficiente angular. Entretanto, estas feições são menos contrastantes em comparação com as feições duplas presente nas imagens do Coeficiente de Hurst.

5.3. Imagens do coeficiente de Hurst utilizando o desvio padrão no cálculo

O emprego do coeficiente de Hurst adotando o desvio padrão em vez da amplitude apresenta uma imagem resultante onde as feições de borda apresentam altos valores de intensidade. A **Figura 14** demonstra o comportamento deste algoritmo considerando diferentes dimensões de janela: (a) 5x5; (b) 7x7; (c) 9x9; e (d) 11x11. Observa-se que à medida que aumenta o tamanho da janela, mais pronunciada fica o delineamento da borda.




Figura 11 – Feição de borda dupla: (a) zoom da imagem do coeficiente de Hurst com uma janela de 17×17 , (b) perfil horizontal com a variação dos valores do coeficiente de Hurst. No zoom da imagem o perfil horizontal está demarcado com a linha vermelha. As setas demonstram a localização entre as mudanças de padrões, ou seja, o limite da borda.




Figura 12 – Operações efetuadas na imagem para a delimitação das feições de borda: (a) imagem relativa ao coeficiente de Hurst a partir de uma dimensão de janela 17×17 ; (b) imagem relativa ao emprego do método NMS proposto com uma dimensão inferior de 15×15 , permitindo salientar o posicionamento da borda; (c) seleção das principais feições de borda a partir do emprego de um valor limite de corte eliminando as feições menos representativas.

Dentre as feições resultantes podem-se distinguir dois tipos: (a) presença de borda entre duas classes distintas como, por exemplo, área de cultivo e áreas de cerrado, que se caracterizam pelo espessamento da borda, e (b) feições lineares como uma entrada com padrões semelhantes nos seus dois lados caracterizados pela presença de feições duplas onde o ponto de mínima corresponde à feição linear.

O método mostra-se também mais sensível a mudança do dimensionamento da janela em comparação ao coeficiente de Hurst gerado pela amplitude. O simples aumento de dois pixels na janela proporciona um acentuado espessamento dos contornos de borda (**Figura 14**). Esta característica ocasiona um aspecto desfocado para imagem que fica mais realçado com o emprego de janelas de maiores dimensões. Desta forma, este algoritmo

A - Coeficiente linear de Hurst - janela 5x5



B - Coeficiente linear de Hurst - janela 9x9



C - Coeficiente linear de Hurst - janela 13x13



D - Coeficiente linear de Hurst - janela 17x17



Figura 13 – Imagens do coeficiente linear do cálculo de Hurst a partir de diferentes dimensões de janela, sendo: (a) 5x5; (b) 9x9; (d) 13x13 e (e) 17x17.


deve ser utilizado com janelas com menores dimensões.

A imagem do coeficiente linear caracteriza-se por ter um comportamento inverso ao coeficiente angular onde as feições de borda são demarcadas por valores de baixa intensidade (**Figura 15**). O coeficiente linear, similarmente ao coeficiente angular, também demonstra características diferentes para as feições das bordas entre classes e feições lineares. Mostra-se também sensível a mudança de

A - Coeficiente de Hurst - Desvio Padrão - janela 5x5



B - Coeficiente de Hurst - Desvio Padrão - janela 7x7



C - Coeficiente de Hurst - Desvio Padrão - janela 9x9



D - Coeficiente de Hurst - Desvio Padrão - janela 11x11



Figura 14 – Imagens do coeficiente de Hurst a partir do desvio padrão considerando diferentes dimensões de janela, sendo: (a) 5x5; (b) 7x7; (c) 9x9; e (d) 11x11.

dimensão da janela e o espessamento das feições lineares.

5.4. Avaliação do coeficiente de Hurst para as diferentes bandas do sensor TM-Landsat

Os métodos foram testados nas diferentes bandas do sensor TM-Landsat. Devido ao comportamento espectral diferenciado entre as bandas os resultados mostram pequenas diferenciações. No entanto, as principais feições


A - Coeficiente de Hurst - Desvio Padrão - janela 5x5



B - Coeficiente de Hurst - Desvio Padrão - janela 7x7



C - Coeficiente de Hurst - Desvio Padrão - janela 9x9



D - Coeficiente de Hurst - Desvio Padrão - janela 11x11



Figura 15 – Imagens do coeficiente linear do cálculo de Hurst considerando o desvio padrão utilizando as seguintes dimensões de janela: (a) 5x5; (b) 7x7; (d) 9x9 e (e) 11x11.

relativas às estradas e as principais bordas entre classes são bem distinguidas em todas as bandas. A banda TM-4 demonstrou um contraste mais específico nas feições de borda relativas ao contato entre as classes de áreas vegetadas e de solo exposto, enquanto que as bandas TM-3, TM-5 e TM-7 permitiram um acentuado destaque para as estradas e demais bordas.

Outro processamento digital complementar que pode ser realizado é a integração das diferentes informações provenientes de todas as bandas em

uma única imagem. Este procedimento adicional pode ser realizado através das operações de média ou de somatório do quadrado (**Figura 16**). A imagem resultante permite uma complementação das informações presentes nos diferentes intervalos espectrais e um realce das principais feições presentes.

6. CONCLUSÃO

Esta metodologia de análise de textura pelo coeficiente de Hurst demonstra ser uma ferramenta promissora no processamento digital de imagens de satélite. As feições de borda nos limites de unidades de uso e cobertura vegetal, tão como feições lineares como estradas podem ser bem delimitadas e caracterizadas pela dimensão fractal.

A fim de aperfeiçoar o método foi elaborado um algoritmo que realiza o cálculo para diferentes dimensões de janelas. Consta-se que o tamanho da janela exerce uma forte influência na distinção das feições espaciais da imagem sendo importante que o usuário disponha deste recurso para otimizar a extração das informações desejadas.

O emprego do algoritmo NMS é adequado ao tratamento das imagens do coeficiente de Hurst, possibilitando uma melhor demarcação das feições de borda permitindo a eliminação das feições duplas. O algoritmo proposto permite um aperfeiçoamento do NMS original considerando quatro direções e maior quantidade de pixels para janelas com dimensões maiores que 5x5.

Outra importante contribuição é o emprego da imagem resultante do coeficiente linear do cálculo de Hurst. Esta imagem, apesar de ser pouco explorada no processamento digital de imagens, apresenta uma excelente qualidade permitindo uma eficaz delimitação das feições de borda. Uma vantagem do seu uso é que não gera feições de duplicação tão pronunciadas como o coeficiente angular.

A utilização do desvio padrão no lugar da amplitude gera imagens do coeficiente de Hurst com um espessamento mais intenso das feições de borda. As imagens do coeficiente linear com este procedimento demonstram valores inversos aos da imagem do coeficiente angular.

Na área de estudo as diferentes bandas do sensor TM-Landsat apresentaram um comportamento complementar. A integração das imagens dos coeficientes angulares ou lineares




Figura 16 – Imagens resultantes das seguintes operações: (A) média dos coeficientes de Hurst utilizando amplitude (9x9) para as bandas do TM-Landsat, (B) média dos coeficientes linear (9x9) utilizando amplitude para as bandas do TM-Landsat, (C) somatório ao quadrado dos coeficientes de Hurst (9x9) utilizando desvio padrão para as bandas do TM-Landsat, e (D) somatório ao quadrado dos coeficientes lineares (9x9) utilizando desvio padrão para as bandas do TM-Landsat.

relativas às diferentes bandas espectrais, por intermédio do somatório ao quadrado, demonstrou ser o método mais eficaz para a detecção das feições de borda.

A principal desvantagem do emprego do coeficiente de Hurst é o fato de ser um processamento ainda relativamente moroso em relação aos outros métodos de análise de textura baseados em filtros estatísticos. Ao calcular a dimensão fractal de uma janela são necessários vários cálculos e o estabelecimento de um algoritmo que minimiza a complexidade computacional e o tempo de processamento torna-se fundamental para a sua aplicação rotineira. O algoritmo desenvolvido obtém uma otimização para o seu emprego. Não obstante, quando se adota janelas de dimensões maiores (11x11) o processo requer um tempo relativamente mais longo de processamento.

AGRADECIMENTOS

Este artigo foi desenvolvido no âmbito das atividades previstas dos seguintes projetos: (a) “Desenvolvimento de metodologias de processamento digital de imagens de satélite multisensores para o monitoramento do uso da terra e análise ambiental dos fragmentos florestais da bacia do Rio São Francisco” referente ao edital 35/2006 do CT-Hidro financiado pelo Conselho Nacional

de Desenvolvimento Científico e Tecnológico (CNPq); (b) “Evolução e análise ambiental na região do Cerrado da Bacia do Rio São Francisco” financiado pela FAP-DF relativo ao processo 193.000.49/2008 e (c) “Análise espacial e histórica dos movimentos sociais e suas relações com o meio ambiente visando a sustentabilidade” financiado pela FINEP. Além disso, os autores agradecem ao CNPq pelas bolsas de produtividade fornecidas aos pesquisadores: Osmar Abílio de Carvalho Júnior, Renato Fontes Guimarães e Roberto Arnaldo Trancoso Gomes; e a bolsa de pós-doutorado para o professor Nilton Correia da Silva.

REFERÊNCIAS BIBLIOGRÁFICAS

- CALDWELL, C. B.; STAPLETON, S. J.; HOLDSWORTH, D. W.; JONG, R. A.; WEISER, W. J.; COOKE, G.; YAFFE, M. J. Characterization of mammographic parenchymal pattern by fractal dimension. *Phys Med Biol.*, v. 35, p. 235-247, 1990.
- CALIGIURI, P.; GIGER, M. L.; FAVUS, M. Multifractal radiographic analysis of osteoporosis. *Med Phys*, v. 21, p. 503–508. 1994.
- CANNY, J. A computational approach to edge detection. *IEEE Transactions on Pattern*

- Analysis and Machine Intelligence**, v. PAMI-8, n. 6, 1986.
- CHEN, C. C.; DAPONTE, J. S.; FOX, M. D. Fractal Feature Analysis and Classification in Medical Imaging. **IEEE Transactions on Medical Imaging**, v. 8, p. 133-142, 1989.
- EAGIAR, A. N.; NAGUIB, R. N. G.; SHARIF, B. S., BENNETT, M.K.; MURRAY, A. Fractal analysis in the detection of colonic cancer images. **IEEE Trans Info Tech Biomed**, v. 6, p. 54–58, 2002.
- GASPAR, M. T. P. **Sistema Aquífero Urucuia: caracterização e propostas de gestão**. 2006. 158 f. Tese (Doutorado em Geociências) – Instituto de Geociências, Universidade de Brasília, Brasília.
- GIBSON, J. J. **The perception of the visual world**. Boston, MA, Houghton Mifflin, 1950.
- HAWKINS, J. K. Textural Properties for Pattern Recognition. In: **Picture Processing and Psychopictorics**, Lipkin B. & Rosenfeld A. (editors), Academic Press, New York, 1969.
- HURST, H.E. Long-term storage capacity of reservoirs. **Trans. Amer. Soc. Civil Engineers**, v. 116, p. 770-799, 1951.
- KAIMOWITZ D, SMITH J. 2001. Soybean technology and the loss of natural vegetation in Brazil and Bolivia. In: Angelsen, A., Kaimowitz, D. (Eds.) **Agricultural Technologies and Tropical Deforestation**, CABI Publishing, New York, pp. 195–211.
- LI, H.; GIGER, M. L.; OLUFUNMILAYO, I.; OLOPADE, O. I.; LAN, L. Fractal analysis of mammographic parenchymal patterns in breast cancer risk assessment. **Acad Radiol**, v. 14, p. 513-521, 2007
- LUNDERVOLD, A. **Ultrasonic Tissue Characterization - A Pattern Recognition Approach, Technical Report**. Norwegian Computing Center, Oslo, Norway, 1992.
- MANDELROT, B. B. **The Fractal Geometry of Nature**. San Francisco, CA: Freeman, 1982.
- MENKE A. B., CARVALHO JUNIOR O. A., GOMES, R.A.T., MARTINS, E. S. & OLIVEIRA S. N. Análise das mudanças do uso agrícola da terra a partir de dados de sensoriamento remoto multitemporal no município de Luis Eduardo Magalhães (Bahia – Brasil). **Sociedade & Natureza**, v. 21, n. 3, p. 315-326, 2009.
- PODSIADLO P, STACHOWIAK GW. The development of the modified Hurst Orientation Transform for the characterization of surface topography of wear particles. **Tribology Letters**, v. 3-4, p. 215–29, 1998.
- PODSIADLO, P.; STACHOWIAK, G.W. Applications of Hurst orientation transform to the characterization of surface anisotropy. **Tribology International**, v. 32, p. 387–392, 1999.
- RUSS J. C. Surface Characterization: Fractal dimensional. Hurst coefficients and frequency transforms. **Journal of Computer Assisted Microscopy**. v. 2, p. 249-257, 1990.
- SMITH J, WINOGRAD M, GALLOPIN G & PACHICO D. Dynamics of the agricultural frontier in the Amazon and savannas of Brazil: analyzing the impact of policy and technology. **Environmental Modeling and Assessment**, v. 3, p. 31–46, 1998.
- STACHOWIAK, G. W. Numerical characterization of wear particles morphology and angularity of particles and surfaces. **Tribology International**, v. 31, n 1–3, p. 139–157, 1998.
- STACHOWIAK, G. W.; PODSIADLO, P. Surface characterization of wear particles. **Wear**, v. 225–229, p. 1171–1185. 1999.
- VITTITOE, N. F, BAKER, J. A., FLOYD, C. E. Fractal texture analysis in computer aided diagnosis of solitary pulmonary nodules. **Acad Radiol**, v. 4, p. 96–101, 1994.
- YAFFE, M. J. Mammographic density. Measurement of mammographic density. **Breast Cancer Research**, 10:209, 2008.
- ZUCKER, S. W.; KANT, K. **Multiple-level Representations for Texture Discrimination**. In: Proceedings of the IEEE Conference on Pattern Recognition and Image Processing, pp. 609- 614, Dallas, TX, 1981.