

# **EMPREGO DA DIMENSÃO FRACTAL PARA SEPARAR CLASSES DE TEXTURA PRESENTES NUMA AEROFOTO DA CIDADE DE PORTO ALEGRE**

## **USE OF FRACTAL DIMENSION TO SEPARATE TEXTURAL CLASSES IN AN AERIAL PHOTOGRAPH OF THE CITY OF PORTO ALEGRE**

Marcos Hirã Arruda Martins<sup>1</sup>

Robin Thomas Clarke<sup>1</sup>

Vitor Haertel<sup>1</sup>

### **RESUMO**

Neste estudo, é investigada a utilização de uma medida chamada *dimensão fractal* para fins de classificação de imagens digitais. A dimensão fractal é capaz de quantificar as características espaciais das superfícies geradas a partir das imagens de sensoriamento remoto, especialmente a textura destas superfícies. Os valores de dimensão fractal são calculados pixel a pixel, segundo o método dos *Prismas Triangulares* e posteriormente organizados num formato matricial ou raster, em uma estrutura similar a uma imagem digital, podendo ser denominados de *bandas fractais*. Estas bandas fractais podem ser utilizadas de forma semelhante às tradicionais bandas espectrais em classificadores convencionais. Esta hipótese foi testada com uma aerofoto digitalizada da cidade de Porto Alegre - RS. Observou-se que as imagens fractais, embora apresentem qualidade visual inferior, proporcionam maior separabilidade entre as classes presentes e possibilitam a obtenção de índices de acerto maiores nas classificações, quando comparadas com a imagem espectral.

*Palavras-chave:* geociências, sensoriamento remoto, classificação fractal.

### **ABSTRACT**

Interest is currently growing in the use of spatial attributes for automatic classification of digital images, as is clearly demonstrated by the increasing number of scientific papers on the topic. The reason for this interest is that some classes in natural scenes are not easily distinguished by the spectral features (urban areas, for instance). Urban areas, in particular, are better defined by spatial attributes, such as texture. This

<sup>1</sup> Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia-Ufrgs

research explores the use of fractal dimension to characterize and separate textural classes present in an aerial photograph of Porto Alegre, capital city of the State of Rio Grande do Sul, Brazil. The fractal dimension can be considered as a measure of the spatial complexity of surfaces generated from remotely-sensed images and it is calculated here over moving windows with 7x7 and 9x9 pixels, using the Triangular Prism method. By using a moving window, it was possible to organise the data in a format similar to that used in spectral bands, thus obtaining fractal-dimension bands, which were converted to digital counter values (between 0 and 255). The Bhattacharya distance was used to estimate the separability between pairs of classes, and Gaussian maximum likelihood was used to classify pixels in the images composed of both fractal and spectral bands. The stronger differentiation between classes, together with the high percentage of successes in test samples, shows that the fractal approach can be useful in automatic classification procedures and in situations where the spectral information alone is not sufficient to distinguish the classes successfully.

**Key-words:** geosciences, remote sensing, fractal classification.

## INTRODUÇÃO

Uma imagem digital de sensoriamento remoto, seja ela oriunda de uma câmera fotográfica ou de um sensor eletro-óptico, possui informações de natureza diversa a respeito da porção da superfície terrestre retratada, sendo a interpretação destas imagens o objetivo final do sensoriamento remoto. Estas informações, contidas nos pixels da imagem, são denominadas de *atributos*. Os atributos podem ser agrupados em três grandes categorias:

- atributos espectrais – relacionados diretamente com a energia eletromagnética (EM) emitida e/ou refletida;
- atributos de contexto – a informação não vem diretamente do pixel individual, mas da sua vizinhança;
- atributos espaciais – textura, forma, dimensão.

Por serem mais facilmente quantificáveis, os atributos espectrais têm sido tradicionalmente os mais utilizados nos processos de classificação automática. No entanto, a crescente difusão do uso de dados de sensoriamento remoto, bem como o aperfeiçoamento dos sistemas sensores, os quais possuem cada vez melhor resolução espectral, espacial, radiométrica e temporal, vêm causando uma crescente demanda por novas metodologias de processamento e classificação.

Outro fato observado em muitas situações práticas é que nem sempre a informação espectral por si só é suficiente para separar as classes presentes numa imagem, tornando necessário o emprego de outros atributos. Artigos recentes têm abordado a classificação baseada em atributos de natureza espacial, especialmente informações a respeito da textura.

Um problema que surge neste particular consiste em quantificar a textura de forma que ela possa ser implementada em ambiente de computador. Este tópico

vem sendo objeto de estudo por parte de vários pesquisadores, conforme mostra a literatura recente nesta área: Chaudhuri e Sarkar (1995), Chaudhuri, Sarkar e Kundu (1993). Uma maneira para quantificar a textura das superfícies geradas a partir das imagens digitais é através da *dimensão fractal* (D).

Para que a dimensão fractal possa ser utilizada em um processo de classificação, é necessário que seu cálculo ocorra em nível local (ou seja, em pequenas regiões), sendo atribuído um valor de D para cada pixel da imagem. Neste estudo, é utilizada a técnica de janela móvel e um método chamado *Prismas Triangulares* para calcular a dimensão fractal em nível local, dando origem a bandas com valores de dimensão fractal (entre 2 e 3) que depois são transformados para valores de contador digital (entre 0 e 255). A imagem utilizada é uma aerofoto da cidade de Porto Alegre-RS, a qual apresenta três classes com texturas distintas: área urbana, área coberta por vegetação e área coberta por água. No plano espectral, estas classes se mostram bastante sobrepostas, o que torna difícil obter uma boa segmentação da imagem. O objetivo deste estudo é verificar como é a qualidade das imagens geradas a partir da dimensão fractal e, em termos quantitativos, avaliar se bandas fractais são capazes de conduzir a melhores resultados em termos de separabilidade das classes e exatidão de classificação.

## FRACTAIS

Não existe uma definição única, completa e fechada sobre o que é um fractal. A rigor, um fractal é descrito como um conjunto de pontos no espaço tal, que a dimensão de Hausdorff-Besicovitch deste conjunto estritamente excede sua dimensão topológica (MANDELBROT, 1983; FEDER, 1988). Enquanto a dimensão de Hausdorff-Besicovitch está ligada aos processos matemáticos utilizados para determinar o *tamanho* de um conjunto de pontos no espaço, a dimensão topológica é estabelecida como zero para pontos, 1 para curvas, 2 para superfícies

e 3 para sólidos. No entanto, segundo Feder (1988), tal definição exclui muitos fractais com aplicações em física. Outra explicação, também encontrada nas obras de Mandelbrot e de Feder, é a seguinte: um fractal é uma figura feita de partes que são de alguma forma similares à figura como um todo. Esta última definição, além de ser menos restritiva, faz referência a uma importante característica dos fractais, ou seja, a da *auto-similaridade*. A auto-similaridade caracteriza-se pelo preenchimento do espaço através da reprodução de uma forma geométrica, mas sempre numa escala de tamanho reduzida, sendo que esta redução se dá a uma razão constante, chamada de *razão de similaridade*.

Em outras palavras, pode-se dizer que os fractais são figuras ou objetos que resultam da atuação de um processo. Este processo consiste em preencher o espaço através da reprodução de uma figura ou objeto original (como se fosse um molde), mas numa escala de tamanho cada vez menor. Quando o fractal é gerado por iterações computacionais, este processo está completamente sob controle e o fractal é dito *verdadeiro*. Quando refere a objetos do mundo real, com características fractais, este processo é do tipo natural, geralmente ligado a algum fenômeno físico, biológico ou geológico, sendo denominado de fractal *não-verdadeiro*. Os fractais verdadeiros apresentam auto-similaridade a todas as escalas e podem ter sua dimensão fractal calculada de forma determinística. Por outro lado, os fractais não-verdadeiros apresentam-se auto-similares apenas dentro de um intervalo limitado de escalas e não podem ter sua dimensão fractal calculada de forma determinística, sendo necessário o emprego de técnicas como a regressão linear

para o cálculo de sua dimensão, em que o valor de  $D$  dependerá do coeficiente angular da reta de regressão.


## SUPERFÍCIES GERADAS A PARTIR DAS IMAGENS DE SENSORIAMENTO REMOTO

Para o entendimento da abordagem fractal, deve-se imaginar uma imagem de sensoriamento remoto como um conjunto de pontos no espaço tridimensional formando superfícies. A complexidade (ou rugosidade) destas superfícies é resultante das variações nos valores de contador digital (CD) destas imagens, os quais são imaginados como elevações situadas no centro dos pixels. Em termos gerais, a dimensão fractal ( $D$ ) é um índice que indica o grau de irregularidade no formato de um fractal e quanto mais irregular for um fractal, maior é o valor de  $D$ . No caso das superfícies, o valor da dimensão fractal irá variar entre 2 e 3.

No contexto das imagens de sensoriamento remoto, quanto mais aleatória for a distribuição espacial dos valores de contador digital, maior o valor da dimensão fractal. Desta forma, uma imagem ruidosa poderia ser relacionada a uma superfície extremamente irregular, sendo esperado que apresentasse um valor calculado de dimensão fractal bastante elevado, próximo de 3. Por outro lado, imagens com pouca variação espacial seriam relacionadas a superfícies planas e apresentariam valores de dimensão fractal próximos de 2. A figura 1 apresenta em (a) uma imagem do setor urbano da cidade Lake Charles/ Louisiana/ EUA, composição entre as bandas 2, 3 e 4 do sensor Landsat/TM. Em (b), é apresentada a superfície formada a partir dos dados da banda 3.



(a)



(b)

Figura 1: Em (a): imagem digital de sensoriamento remoto. Em (b): superfície formada a partir dos valores de contador digital da banda 3 (adaptação de Lam, 1990, p. 190 e 192). (a): *Remote-sensed digital image*. (b): *surface generated from the digital counter values of band number three* (adaptation from Lam, 1990, p. 190, 192).




Figura 2: Superfícies construídas a partir de dados simulados. Os valores de dimensão fractal são estabelecidos a priori. Diferentes níveis de complexidade espacial estão associados a diferentes valores de dimensão fractal (adaptação de Lam, 1990, p. 188). *Surfaces built from simulated data. The fractal dimension values are fixed a priori. Different levels of spatial complexity are associated with different values of fractal dimension (adaptation from Lam, 1990, p. 188).*

## RELAÇÃO ENTRE DIMENSÃO FRACTAL E A COMPLEXIDADE ESPACIAL DAS SUPERFÍCIES

Pentland (1984) observou que há uma relação direta entre a dimensão fractal e a complexidade espacial das superfícies (rugosidade). Seus experimentos mostraram elevados valores de correlação ( $>0,9$ ) entre níveis de rugosidade atribuídos pela visão humana e valores de dimensão fractal de superfícies produzidas a partir de dados simulados. A figura 2 apresenta quatro superfícies artificiais com valores conhecidos de dimensão fractal. De (a) para (d) percebe-se um aumento da complexidade espacial, o qual é acompanhado por uma elevação nos valores de dimensão fractal.

Subjacente a este estudo está a idéia de que diferentes classes de textura em imagens podem ser descritas por diferentes valores de dimensão fractal. Esta suposição também está presente nos trabalhos de Emerson et

al. (1999), De Jong e Burrough (1995), Chaudhuri e Sarkar (1995) e Pentland (1984). Por outro lado, há estudos descritos na literatura mostrando evidências de que, mesmo texturas diferentes podem apresentar valores de dimensão fractal bastante parecidos (KELLER et al., 1988).

## METODOLOGIA

Para o cálculo da dimensão fractal empregou-se o método dos Prismas Triangulares proposto por Clarke (1986). Por este método, a imagem é dividida em quadrados de diferentes tamanhos, sendo interpolado um valor de elevação no centro de cada quadrado, o qual resulta da média aritmética dos valores de contador digital dos 4 pixels extremos do quadrado. Conectando-se esta elevação central àquelas representadas pelos quatro pixels extremos, obtém-se uma estrutura geométrica como a mostrada na figura 3.




Figura 3: Estrutura geométrica considerada no cálculo da dimensão fractal, segundo o método dos Prismas Triangulares. Quadrados com dimensão 3x3 pixels (adaptação de De Jong e Burrough, 1995, p. 1044). *Geometric structure used to calculate fractal dimension using the Triangular Prism method. Squares with 3x3 pixels (adaptation from De Jong and Burrough, 1995, p. 1044).*

Sobre cada quadrado formam-se quatro triângulos cujos comprimentos dos lados e os ângulos internos dependem das variações nos valores de contador digital. Para cada tamanho de quadrado, imagina-se a imagem inteira coberta por triângulos, obtendo-se o valor correspondente à soma das áreas de todos os triângulos. Quando se altera o tamanho dos quadrados, altera-se também a área total, mas sempre no sentido inverso. Para o cálculo das áreas dos triângulos, são utilizadas as fórmulas de Pitágoras e de Heron. O coeficiente angular da reta de regressão entre as variáveis  $\ln(\text{área total})$  e  $\ln(\text{tamanho do quadrado})$  é utilizado no cálculo final da dimensão fractal da superfície:

$$D = 2 - b \quad (1)$$

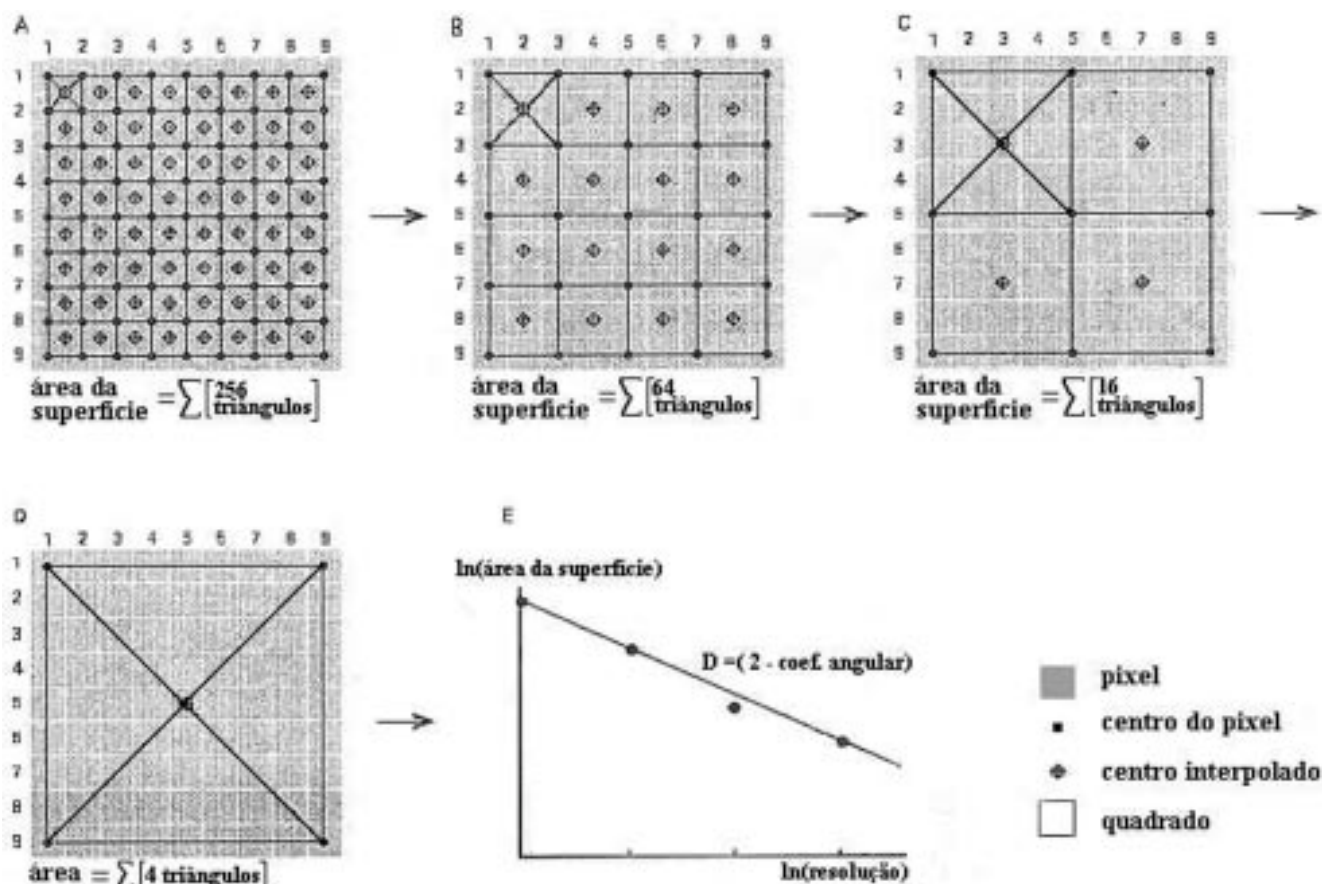
onde  $b$  é o coeficiente angular. No presente estudo, o método foi aplicado em nível local, ou seja, sobre regiões com dimensão 7 x 7 e 9 x 9 pixels, o que permitiu consi-

derar quatro diferentes tamanhos de quadrados e quatro pontos amostrais em cada regressão. Embora a utilização de apenas quatro pontos nas regressões possa deixar margem a grandes flutuações nos resultados devidas ao acaso, há necessidade de limitar o tamanho dessas áreas locais, pois à medida que janelas móveis maiores são utilizadas, ocorre um empobrecimento qualitativo das imagens. A figura 4 resume todo o processo quando consideram-se regiões com dimensão 9 x 9 pixels.

Após todos os cálculos terem sido realizados, o pixel central da janela móvel recebe o valor de dimensão fractal e a janela se desloca uma posição, quando então se reiniciam os cálculos. Após esta etapa, os valores de dimensão fractal (entre 2 e 3) são convertidos para valores de contador digital (entre 0 e 255), a fim de que possam ser utilizados nos processamentos subsequentes.

Para a classificação das imagens, o algoritmo empregado foi o da máxima verossimilhança gaussiana. Esta técnica é uma das mais freqüentemente emprega-





das na classificação de imagens digitais de sensoriamento remoto, inserindo-se no grupo dos métodos estatísticos de classificação supervisionada (RICHARDS, 1993).

Para estimar o poder de separabilidade das classes, tanto dos dados espectrais como das imagens formadas a partir da dimensão fractal, optou-se pela distância de Bhattacharya. A distância de Bhattacharya é uma medida empregada freqüentemente em processos de seleção de bandas para classificação (feature selection). Quanto maior o valor estimado de distância, aqui denotado por B, maior é a separabilidade entre as classes. A distância B assume valores entre zero e infinito e, sob suposição de normalidade dos dados, é calculada por:

$$B = \frac{1}{8} (\mu_1 - \mu_2)^2 [(\sigma_1^2 + \sigma_2^2) / 2]^{-1} + \frac{1}{2} \ln [(\sigma_1^2 + \sigma_2^2) / 2\sigma_1\sigma_2] \quad (2)$$

$$B \in (0, +\infty) \quad (\text{caso univariado})$$

onde

$\sigma_1$  e  $\sigma_2$  são as variâncias nas classes 1 e 2, sendo

$\mu_1$  e  $\mu_2$  as médias nas classes 1 e 2.



Figura 5: Área de estudo: inclui parte da região central de Porto Alegre, do Guaíba e ilhas. Nota-se a presença de três classes com texturas distintas: 1) área urbana, 2) vegetação e 3) água. *Study area: includes part of central Porto Alegre, part of the Guaíba and its islands. Note the presence of three classes with distinct textural features: 1) urban area, 2) vegetation and 3) water.*




Figura 6: Histogramas das 3 classes presentes na imagem espectral. Em (a): área urbana, em (b): vegetação, em (c): água; f: frequência. *Histograms of three classes present in the spectral image. In (a): urban area, (b): vegetation, (c): water; f: frequency.*

Tabela 1: estatísticas descritivas baseadas nos valores de contador digital das amostras das três classes presentes na imagem espectral; n= tamanho da amostra.

Classe	n	Mínimo	Máximo	Média	Desvio-padrão
Urbana	396	24	255	154,27	41,67
Vegetação	400	159	226	195,59	13,12
Água	405	115	146	128,91	6,18

O método dos Prismas foi implementado em linguagem Matlab (1999) e os processamentos de classificação e cálculo de distância foram realizados com o programa Multispec. Este programa foi desenvolvido na Purdue University - West-Lafayette, Indiana, EUA, tendo sua elaboração financiada em parte por um contrato com a Nasa.

## ÁREA DE ESTUDO

Com a finalidade de ilustrar e testar a metodologia proposta, optou-se por uma imagem real obtida através da digitalização de uma fotografia aérea em tons de cinza da cidade de Porto Alegre - RS, datada de 1978 e gentilmente cedida pelo Departamento Autônomo de Estradas de Rodagem - Daer. A figura 5 mostra a área de estudo que abrange a região central da cidade, uma parte do lago Guaíba e a Ilha do Ingles. Nota-se a presença de três classes com texturas bem distintas: 1) área urbana, 2) área coberta por vegetação e 3) área coberta por água. A dimensão da imagem é 133 x 384 pixels e a resolução espacial é 10 m.

Três amostras, com aproximadamente 400 pixels, foram extraídas de cada uma das classes da imagem espectral (figura 5). Os histogramas destes dados são mostrados na figura 6 e as estatísticas descritivas, na tabela 1.

Verifica-se, através da figura 6 e da tabela 1, que há sobreposição entre os pares de classes (urbana, água e urbana, vegetação). Além disso, fica evidente a grande diferença de dispersão entre as classes. A sobreposição entre classes costuma ser um aspecto que dificulta a obtenção de bons resultados nas classificações. No entanto, por levar em consideração a variabilidade dos dados, o classificador gaussiano pode tirar vantagem da grande diferença de dispersão verificada entre as três clas-

ses. A área urbana é extremamente difícil de ser classificada por meio de atributos espectrais. Trata-se, na realidade, de uma *classe de informação* e não de uma classe espectral. Do ponto de vista espectral, esta área se constitui em uma mistura de classes espectrais (vegetação, asfalto, telhados), gerando desta forma um misto multimodal.

## RESULTADOS E DISCUSSÃO

As figuras 7 e 8 apresentam as imagens resultantes do processamento com o método dos Prismas, considerando os janelamentos 7 x 7 e 9 x 9 pixels, respectivamente. Em termos qualitativos, é possível notar alguma semelhança com a imagem espectral (figura 5), já que as três classes apresentam tonalidades características, percebendo-se ainda que os limites entre as classes se mantiveram praticamente constantes. No entanto, já não é mais possível identificar as estruturas conhecidas na parte urbana (mercado público, avenidas), sendo este um efeito esperado da técnica de janelamento, a qual ocasiona um certo grau de embaciamento da imagem. A imagem resultante do processamento 9 x 9 é ainda mais pobre em termos visuais, devido ao maior tamanho da janela móvel. Em geral, os maiores valores de contador digital ocorrem na parte urbana, pois é este o setor com maior complexidade espacial, onde estão presentes pixels pertencentes a outras classes, assim como pixels sombra. A região coberta por água apresenta-se mais escura (valores baixos de dimensão fractal) devido ao fato desta parte da imagem ser a de menor complexidade espacial, ou seja, o algoritmo capta apenas mudanças sutis das áreas dos triângulos à medida que se alteram os tamanhos dos quadrados.



Figura 7: Imagem resultante do processamento com o método dos Prismas e janela móvel com dimensão 7 x 7 pixels. Output image given by the Triangular Prism method with moving window 7 x 7.





Figura 8: Imagem resultante do processamento com o método dos Prismas e janela móvel com dimensão 9 x 9 pixels. *Output image given by the Triangular Prism method with moving window 9 x 9.*

A tabela 2 resume os resultados referentes às distâncias entre os pares de classes nos três conjuntos de dados. Para esta análise, foram retiradas amostras com 100 pixels da classe urbana, 88 pixels da classe vegetação e 72 da classe água, nos três conjuntos de dados.

O poder discriminatório dos dados espectrais se mostra maior do que o das imagens fractais para o par de classes (vegetação, água). No entanto, a menor entre todas as distâncias também ocorre com os dados espectrais (0,96), no par (urbana, vegetação). A banda fractal resultante do processamento com janela móvel

9 x 9 fornece a maior distância entre os pares (urbana, vegetação e urbana, água), justamente os pares de classes com maior sobreposição de valores nos dados espectrais.

As classificações com os três conjuntos de dados se basearam em amostras de treinamento e de teste. Além disso, considerou-se a possibilidade do classificador rotular como *pixels não-classe*, aqueles pixels com probabilidade a posteriori muito baixa em todas as classes. As tabelas 3, 4 e 5 resumem os resultados quantitativos das classificações.

Tabela 2: Estimativa da separabilidade entre os pares de classes por intermédio da distância de Bhattacharya (B). Dados espectrais, Prismas 7 x 7 e Prismas 9 x 9. Amostras: 100 pixels da classe urbana, 88 pixels da classe vegetação e 72 da classe água. *Separability estimation among pairs of pairs by means of Bhattacharya distance (B). Spectral data, 7 x 7 Prisms, and 9 x 9 prisms. Samples: 100 pixels of urban class, 88 pixels of vegetation class and 72 water class.*

Classes	Imagem Espectral	Imagem Prismas 7 x 7	Imagem Prismas 9 x 9
(urbana, vegetação)	0,96	1,95	3,98
(vegetação, água)	22,10	2,54	3,88
(urbana, água)	1,12	5,78	12,00

Tabela 3: Resultados da classificação com os dados espectrais. *Classification results with spectral data.*

	Não classe	Urbana	Vegetação	Água	Total	Exatidão Média (%)
<b>Urbana</b>	6	60	7	7	80	
<b>Vegetação</b>	0	10	71	0	81	84,3
<b>Água</b>	0	8	0	73	81	
<b>Total</b>	6	78	78	80	242	

Tabela 4: Resultados da classificação com os dados gerados segundo o método dos Prismas com janelamento 7 x 7. *Results of classification with data generated according to Prism method with 7 x 7 Windows.*

	Não classe	Urbana	Vegetação	Água	Total	Exatidão Média (%)
<b>Urbana</b>	0	71	6	0	77	
<b>Vegetação</b>	0	0	57	6	63	94,56
<b>Água</b>	1	0	0	98	99	
<b>Total</b>	1	71	63	104	239	

Tabela 5: Resultados da classificação com os dados gerados segundo o método dos Prismas com janelamento 9 x 9. *Results of classification with data generated according to Prisms methods with 9 x 9 Windows.*

	Não classe	Urbana	Vegetação	Água	Total	Exatidão Média (%)
<b>Urbana</b>	3	97	0	0	100	
<b>Vegetação</b>	1	0	107	0	108	98,62
<b>Água</b>	0	0	0	81	81	
<b>Total</b>	4	97	107	81	239	

A exatidão média é obtida através da divisão do total de pixels corretamente classificados (valores da diagonal) pelo total geral de pixels das amostras de teste. Percebe-se uma grande diferença na exatidão média, considerando dados espectrais e fractais (14,32%). Estes resultados sugerem que as classes consideradas se diferenciam mais pela informação espacial do que pela informação espectral.

Alguns resultados de distâncias (tabela 2) podem estar relacionados com os resultados das classificações (tabelas 3 até 5). Na tabela 2 é visto que a separabilidade estimada para o par (urbana, vegetação), nos dados espectrais, é a mais baixa entre todas. Na classificação, tem-se um elevado percentual de pixels confundidos entre estas duas classes nos dados espectrais: 14,9%. Da mesma forma, o maior valor de distância para os três conjuntos de dados é 22,1, o qual se verifica para o par de classes (vegetação, água) nos dados espectrais. Na tabela 3, verifica-se que não houve confusão entre estas duas classes. Com relação à imagem Prismas 9 x 9,

tem-se um elevado valor de distância para o par (urbana, água) e nenhum pixel confundido entre estas duas classes na classificação.

A figura 9 mostra a imagem Prismas 9 x 9 classificada. Em geral, as fronteiras entre as classes foram estabelecidas corretamente, ocorrendo uma certa confusão no limite entre os setores urbano e água, onde muitos pixels foram classificados como vegetação. O problema da técnica de janela móvel reside principalmente nas regiões de fronteira, devido à abrangência de mais do que uma classe ao mesmo tempo pela janela. A minimização deste efeito muitas vezes passa por alguma técnica de processamento adicional, tal como a de *relaxação probabilística*, em que a probabilidade a posteriori é reestimada com base nas informações trazidas por pixels vizinhos. O resultado final esperado com a aplicação desta técnica seria o de uma imagem bem menos ruidosa e com fronteiras mais bem definidas (RICHARDS, 1993, p. 196).




Figura 9: Imagem Prismas 9 x 9 classificada. *Prismatic image 9 x 9 after classification.*

## CONCLUSÕES

Verificou-se que as imagens fractais podem proporcionar valores de separabilidade entre classes que em geral são maiores do que aqueles verificados com imagens espectrais. A maior separabilidade conduziu também a resultados melhores nas classificações, as quais apresentaram níveis de exatidão média até 14,32% superiores, com a informação espacial. O janelamento 7 x 7, embora produza uma imagem com qualidade visual superior, mostra um desempenho ligeiramente inferior ao janelamento 9 x 9 em termos de separabilidade das classes e exatidão de classificação.

Os resultados obtidos no processamento e análise da imagem de Porto Alegre indicam que a dimensão fractal pode ser uma medida útil em situações nas quais

não é possível separar duas classes com base apenas na informação espectral. As imagens geradas a partir dos valores de dimensão fractal, calculados segundo o método dos Prismas Triangulares e transformados para valores de contador digital, mostram-se superiores na separação de classes que antes se encontravam sobrepostas. Desta forma, conclui-se que classes de informação (multimodais) podem ser bem individualizadas por suas características espaciais, tais como a textura.

## AGRADECIMENTOS

Ao Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia da UFRES pelo apoio material e técnico. A Capes pelo apoio financeiro (bolsa de mestrado).

## REFERÊNCIAS

- CHAUDHURI, B. B.; SARKAR, N. Texture Segmentation Using Fractal Dimension. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, n.17, p. 72-76, 1995.
- CHAUDHURI, B. B.; SARKAR, N.; KUNDU, P. An Improved Fractal Geometry Based Texture Segmentation Technique. *Proc IEE-part E*, n. 140, p. 223-241, 1995.
- CLARKE, K. C. Computation of the Fractal Dimension of Topographic Surfaces Using the Triangular Prism Surface Area Method. *Computers & Geosciences*, n. 12, p. 713-722, 1986.
- DE JONG, S. M.; BURROUGH, P. A. A Fractal Approach to the Classification of Mediterranean Vegetation Types in Remotely Sensed Data. *Photogrammetric Engineering and Remote Sensing*, v. 56, p. 1041-1053, 1995.
- EMERSON C. W.; LAM, N. S.-N.; QUATTROCHI, D. A. Multi-Scale Fractal Analysis of Image Texture and Pattern. *Photogrammetric Engineering and Remote Sensing*, v. 65, n. 1, p. 51-61, 1999.
- FEDER, J. *Fractals*. New York: Plenum Press, 1988. 283 p.
- KELLER, J. M.; CHEN, S.; CROWNOVER, R. M. Texture Description and Segmentation through Fractal Geometry. *Computer Vision, Graphics, and Image Processing*, n. 45, p. 151-166, 1989.
- LAM, N. S.-N. Description and Measurement of Landsat TM Images Using Fractals. *Photogrammetric Engineering and Remote Sensing*, v. 56, n. 2, p. 187-195, 1990.
- MANDELBROT, B. B. *The Fractal Geometry of Nature*. New York, W. H: Freeman and co, 1983. 468 p.

MATLAB. *Guia do Usuário*. Itaim-Bibi, São Paulo: Makron Books do Brasil, 1999.

MULTISPEC. *Manual*. School of Electrical and Computer Engineering of Purdue University.

PENTLAND, A. P. Fractal-Based Description of Natural Scenes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 6, n. 6, p. 661-674, 1984.

RICHARDS, J. *Remote Sensing Digital Image Analysis*. 2 ed. Austrália: Springer-Verlag, 1993. 340 p.