

UTILIZAÇÃO DE PARÂMETROS DE FORMA COMO DADO AUXILIAR NA CLASSIFICAÇÃO DE IMAGENS IKONOS ATRAVÉS DE REDES NEURAI ARTIFICIAIS

ANDRÉA FARIA ANDRADE
JORGE SILVA CENTENO
HIDEO ARAKI

Curso de Pós-Graduação em Ciências Geodésicas - UFPR
Departamento de Geomática - UFPR
Departamento de Geomática - UFPR
andrefar@ig.com.br
centeno@geoc.ufpr.br

RESUMO - A classificação de imagens de sensoriamento remoto tem sido um importante processo para a produção de mapas temáticos, e uma das principais fontes de dados para os sistemas de informações geográficas. E a mesma tem sido aperfeiçoada em decorrência do avanço da tecnologia dos novos sensores. Com isto, a eficiência dos algoritmos de classificação espectral passou a ser questionada e novos métodos que ajudem na extração de informações são processadas. A utilização de Redes Neurais Artificiais emerge como uma alternativa vantajosa aos classificadores baseados em conceitos estatísticos, uma vez que nenhuma hipótese prévia sobre a distribuição dos dados a serem classificados é exigida e os dados de entrada podem ter escalas diferentes. A análise de forma e tamanho é uma poderosa ferramenta para a discriminação de objetos que possuem a mesma aparência espectral. O objetivo principal deste trabalho é a integração da informação a respeito da forma dos objetos, principalmente de construções, no processo de classificação utilizando Redes Neurais Artificiais.

ABSTRACT - The classification of remote sensing images has been an important process for thematic mapping, and one of the main sources for geographic information systems. And has been improved as a result of the development of new sensors technology. Because of that, the efficiency of spectral classification algorithms was put in doubt and new methods are needed to extract information. Artificial Neural Nets arises as a powerful choice to the statistics based classifiers, since no previous information or hypotheses about data distribution is required and input data can have different scales. Shape and size analysis is a powerful tool for discrimination of objects with the same spectral aspect. The aim of this work is the study of the use of auxiliary input information based in the shape of the objects (especially buildings) in the classification of an IKONOS II image through Artificial Neural Nets.

1 INTRODUÇÃO

De acordo com MEYER; WERTH (1990), cerca de 95% de toda classificação procura realizar a tarefa de fotointerpretação (feita por um analista com inúmeras variáveis), usando apenas uma variável, a cor ou tons de cinza. Portanto não é surpreendente que haja erros em mapas temáticos provenientes da classificação. Vários cientistas sabendo desta condição tentaram aumentar a acurácia e a qualidade da classificação derivada do sensoriamento remoto através da incorporação de dados auxiliares no processo de classificação (MASON et al., 1988; HUTCHINSON, 1982; FRANKLIN et al., 1992).

Entre outros aspectos que podem ser explorados encontram-se a textura, o tamanho e a forma dos objetos, bem como a associação espacial entre os objetos que compõem a cena. Classificadores tradicionais, baseados em princípios estatísticos, são os que habitualmente

encontram-se implementados na maioria dos softwares utilizados em processos de extração de informações de imagens provenientes de sensoriamento remoto.

A análise de forma e tamanho é uma poderosa ferramenta para a discriminação de objetos que possuem a mesma aparência espectral. Considerando, por exemplo, duas regiões de uma imagem ocupadas por construções e asfalto, espectralmente na maioria das vezes ambas apresentam aparência espectral muito similar, de maneira que sua discriminação não seja possível. Isto, no entanto, pode se tornar mais fácil se for levado em consideração que construções possuem uma forma retangular, ao contrário do asfalto que já possui uma forma mais alongada.

Assim como a análise espectral baseia-se nos valores digitais das bandas, é necessário dispor de um parâmetro de forma e tamanho para descrever a forma dos objetos. Para analisar a forma é necessário conhecer os

limites dos objetos nas imagens, algo que a princípio é desconhecido. Por isto, os algoritmos de análise de forma partem de uma imagem temática, se possível binária, onde os objetos se encontrem mais definidos. A imagem temática pode ser o resultado de uma classificação supervisionada, ou a segmentação da imagem.

Entre os parâmetros utilizados como descritores da variação espacial do objeto encontram-se: Área (A), Perímetro (P), Coeficiente de Compacidade (cc), número de forma e teoria dos fractais, através da análise da dimensão fractal (D). Neste trabalho, o uso integrado da informação espectral, junto com parâmetros de forma é pesquisado, a fim de se reconhecer objetos em imagens de alta resolução. Como elemento integrador, as redes neurais artificiais são utilizadas.

A utilização de Redes Neurais Artificiais emerge como uma alternativa vantajosa aos classificadores baseados em conceitos estatísticos, uma vez que nenhuma hipótese prévia sobre a distribuição dos dados a serem classificados é exigida e os dados de entrada podem ter escalas diferentes.

2. ANÁLISE DA FORMA

Entre os parâmetros utilizados como descritores da variação espacial do objeto encontram-se (BÄSSMAN; KREYSS, 1998): área (A); perímetro (P); coeficiente de compacidade (cc); distância polar ao centro de gravidade; relação entre os eixos menor e maior da elipse que melhor se aproxima do objeto; descritores de *Fourier*; sinuosidade dos contornos; dimensão Fractal (D).

Há várias outras maneiras de representar e descrever a variação da forma dos objetos, como através da teoria do código da cadeia, teoria das assinaturas, dos números de formas, circularidade, entre outras (GONZALES; WOODS, 2000).

2.1 Área e perímetro

São os mais simples descritores utilizados, e partir da imagem binarizada, a área é obtida contando todos os pixels que formam a região, e o perímetro é calculado através da soma de todos os pixels que possuem um vizinho com valor diferente ao da região.

2.2 Coeficiente de compacidade

O coeficiente de compacidade mede o grau de semelhança entre a região e uma circunferência de igual área. Normalmente os fatores de forma são definidos para variar entre 0 e 1. O valor do coeficiente de compacidade de uma circunferência é 1. Este valor cresce na medida em que o contorno do objeto se torna irregular, ou seja, menos compacto. O coeficiente de compacidade (cc), é obtido através da equação 1:

$$cc = \frac{P^2}{4\pi A} \quad (1)$$

De acordo com FACON (1993), o coeficiente de compacidade (cc) é invariante na mudança de escala, já que o mesmo depende dos descritores simples como a área e o perímetro que não dependem da mudança de escala. A compacidade é também invariante na translação e na mudança de orientação.

2.3 Distância polar ao centro de gravidade

Para os cálculos da distância polar, é necessário primeiramente determinar a origem do sistema. Como padrão, costuma-se usar o centro de gravidade da figura. Para cada pixel do contorno da imagem é então medida a distância à origem e esta variação é armazenada sob a forma de uma série de números ou representada como um gráfico (GONZALES; WOODS, 2000).

2.4 Descritor de *Fourier*

Os descritores de Fourier são obtidos da transformada de Fourier da função descrita pela borda da figura devidamente discretizada, utilizando-se um método para mapear os pontos da borda em termos de coordenadas (X, Y) num vetor. Aplicando-se a transformada de Fourier à este valor, resulta um vetor com componentes:

$$f_0, f_1, f_2, f_3, \dots, f_n$$

que são os descritores de Fourier do contorno da figura. O termo f_0 corresponde a média da forma.

2.5 Relação eixo menor e maior da elipse

A informação do contorno é apresentada por este descritor através da razão dos eixos menor e maior da elipse que mais se ajusta ao objeto ou elemento analisado. Estes eixos podem ser obtidos através da obtenção dos componentes principais de cada segmento, através dos autovalores e autovetores calculados.

2.6 Sinuosidade do contorno

A sinuosidade do contorno dos segmentos pode ser verificada desenhando diferentes objetos, conforme pode-se observar através da Figura 1, com a mesma área mas com contornos ou perímetros diferentes. O maior perímetro corresponde ao maior valor de sinuosidade de contorno, que corresponde à razão entre os dois perímetros analisados. Portanto o coeficiente de forma pode ser obtido através da equação 2 abaixo:

$$sc = \frac{P_1}{P_0} \quad (2)$$

onde:

sc = coeficiente de sinuosidade do contorno;
 P_0 = perímetro do primeiro objeto (elemento);
 P_1 = perímetro do segundo objeto (elemento);

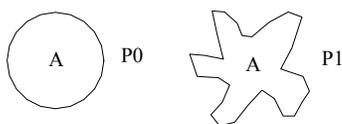


Figura 1 – Objetos com áreas iguais, porém com perímetros diferentes.

2.7 Código da cadeia

O código da cadeia é usado na representação da fronteira por uma seqüência conectada de segmentos de linha reta de determinado tamanho e direção. Essa representação baseia-se tipicamente na conectividade-de-4 ou na de-8 dos segmentos. A direção de cada segmento é codificada por um esquema de numeração como o mostrado na Figura 2 (GONZALES; WOODS, 2000).

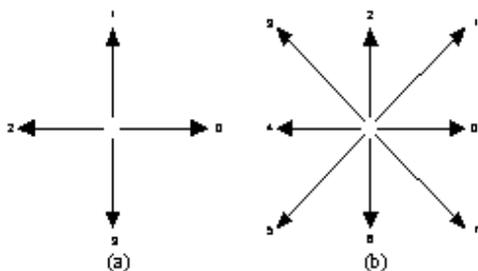


Figura 2 – Direções do (a) código da cadeia direcional-de-4 e (b) direcional-de-8.

Um exemplo simples para a representação deste descritor pode ser observado através da Figura 3, o início da descrição do código é no canto superior esquerdo da forma.

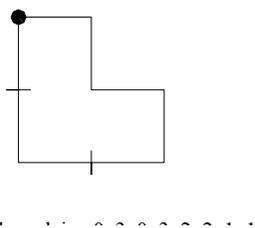


Figura 3 – Representação da forma através do código da cadeia.

2.8 Número de forma

Como o número de forma depende do ponto inicial e da rotação da região, o mesmo não é um descritor eficiente, mas ele pode ser utilizado para calcular o número de forma, que é uma representação normalizada do contorno. O número de forma de tal fronteira é baseado no código direcional-de-4. A ordem n deste método é o número de dígitos em sua representação. A Figura 4 mostra a representação da forma de ordem 6,

juntamente com o código da cadeia e a sua normalização. Embora a normalização do código da cadeia seja independente de rotação, a fronteira codificada geralmente depende da orientação da grade.

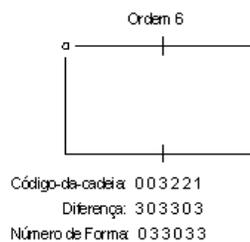


Figura 4 – Representação número de forma ordem 6.

Uma maneira de normalizar a grade, é definindo-se uma caixa retangular (retângulo básico) envolvendo a fronteira, sendo esta definida através dos eixos maior e menor da fronteira, conforme pode ser visto na Figura 5(b). A razão entre o maior e o menor eixo é a excentricidade da fronteira. Na maioria dos casos um único número de formas é obtido alinhando-se a grade do código da cadeia aos lados do retângulo básico.

Passos para a geração do número de forma:

- 1) Supondo que $n=18$ seja especificado para a fronteira da Figura 5(a), obtém-se então o retângulo básico, como mostrado na Figura 5(b);
- 2) Achar um retângulo tal que sua excentricidade melhor aproximar do retângulo básico, para o estabelecimento do tamanho da grade. Neste caso o retângulo mais próximo de ordem 18 seria um retângulo 3×6 , onde requer a subdivisão do retângulo básico, como mostra a Figura 5(c), sendo que as direções do código da cadeia terão que estar alinhadas com a grade resultante;
- 3) O último passo é a obtenção do código da cadeia e a utilização de sua primeira diferença no computo do número de forma, conforme mostra a Figura 5(d).

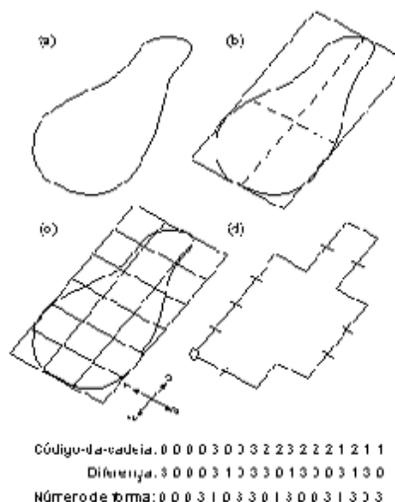


Figura 5 – Passos na geração do número de forma.

2.9 Dimensão fractal

Fractais foram definidos por MANDELBROT (1977) como "um padrão formado por partes similares ao longo de alguma forma" (FEDER apud DE COLA, 1989). A Análise Fractal seria o "estudo de fenômenos complexos manifestando auto-similaridade em muitas escalas" (DE COLA, 1989).

Uma dimensão fractal (D) constante em diferentes escalas indica auto-similaridade dos objetos (MILNE apud LAGRO, 1991), ou seja, cada porção pode ser considerada uma imagem em escala reduzida do todo (LAM, 1990) e mudanças significativas na forma deveriam refletir em mudanças na Dimensão Fractal (KRUMMEL et al. apud LAGRO, 1986).

Segundo PALMER (1988), a dimensão fractal pode ser utilizada como um índice da dependência espacial de uma variável. A geometria fractal vem sendo muito utilizada por permitir a descrição de padrões ecológicos que não são facilmente descritos pela geometria Euclidiana, como linhas, planos esferas e cubos. Formas mais complexas deveriam produzir um dimensão fractal próxima de 2, enquanto quadrados e círculos ou formas geométricas simples apresentariam dimensão fractal igual a 1 (LAGRO, 1991).

A Dimensão Fractal é calculada através do ajuste do modelo de Regressão Linear (DE COLA, 1989):

$$\ln(p_j) = \ln(c) + D \ln(S_j^{1/2}) + \varepsilon \quad (3)$$

onde:

p_j = perímetro das regiões;

c = índice de forma;

D = dimensão fractal;

S_j = área das regiões.

Segundo DE COLA (1989), cada feição natural ou artificial existente no terreno possui um dimensão fractal característica, que permite diferenciá-la de outras feições.

3 MATERIAIS E MÉTODOS

A imagem utilizada para este estudo foi um recorte da imagem híbrida IKONOS II da região do Município de Matinhos, região do Litoral Paranaense, resultante da fusão da banda pancromática com as bandas 2, 3 e 4.

Os passos seguidos no processo de extração de construções a partir de imagens IKONOS são apresentados a seguir. O processo inicia com a classificação (ou segmentação) da imagem, identificando neste passo as classes espectralmente similares. A seguir estas regiões são pesquisadas em detalhe. Para isto é necessário o pré-processamento da imagem temática e o reconhecimento dos grupos de pixels candidatos. Para estes grupos, os parâmetros de forma são calculados. Finalmente, os dados a respeito da forma, junto com a informação espectral média dos segmentos, servem de entrada numa rede neural, que discrimina os objetos presentes na imagem.

3.1 Extração de regiões

De acordo com MASCARENHAS, VELASCO (1989), região é um conjunto de pontos "conectados", ou seja, de qualquer ponto da região pode-se chegar a qualquer outro ponto por um caminho inteiramente contido na região. As regiões que se deseja detectar, geralmente são regiões "homogêneas", ou seja, apresentam alguma propriedade local aproximadamente constante em toda sua extensão. Algumas propriedades locais comumente utilizadas são nível de cinza, textura e cor.

A segmentação é um processo em que uma imagem é subdividida em partes ou objetos constituintes. Os algoritmos de segmentação são geralmente baseados em uma das seguintes propriedades básicas de valores de cinza: descontinuidade e similaridade. Na primeira categoria a abordagem é dividir a imagem procurando mudanças bruscas nos níveis de cinza. As principais áreas de interesse nessa categoria são a detecção de pontos isolados e detecção de linhas e bordas na imagem. As principais abordagens da segunda categoria baseiam-se em limiarização, crescimento de regiões e divisão e fusão de regiões (GONZALES; WOODS, 2000).

Outra maneira de identificar pixels com propriedades espectrais semelhantes é a classificação. Neste caso, no entanto, não há garantia de que os pixels estejam conectados. Segundo CHUVIECO (1990), o processo de classificação de imagens é de grande importância no processamento digital de imagens, e este consiste na associação de cada pixel da mesma a um "rótulo" que descreve um objeto da superfície terrestre gerando uma nova imagem, onde é associada uma cor para cada classe e todos os pixels ou elementos pertencentes a esta classe possuem a mesma cor. Quando este tipo de operação é efetuado para todos os pixels da imagem, o resultado é um mapa temático, mostrando a distribuição geográfica das classes que compõe a cena classificada.

A classificação também pode ser aplicada a regiões previamente identificadas. Os classificadores por regiões utilizam, além da informação espectral de cada pixel, a informação espacial que envolve a relação entre os pixels e seus vizinhos. Estes classificadores procuram simular o comportamento de um foto-intérprete, ao reconhecer áreas homogêneas de imagens, baseados nas propriedades espectrais e espaciais de imagens (LILLESAND; KIEFER, 1994).

Para a obtenção da imagem temática, a fim de se discriminar os vários segmentos de cada padrão da imagem, foi realizada uma classificação puramente espectral através do método das redes neurais artificiais, de onde se pode obter uma imagem contendo um número restrito de classes para uma posterior análise dos parâmetros de forma dos segmentos gerados pela classificação. Para tanto se utilizou o software ENVI. Na Figura 6, pode-se observar o resultado desta classificação como também os padrões onde houve confusão devido a apresentarem respostas espectrais similares.

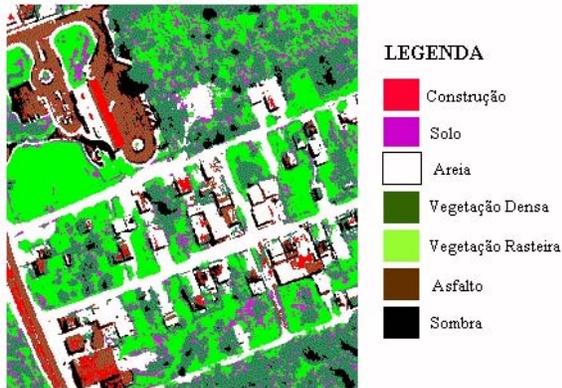


Figura 6 – Resultado da classificação pixel-a-pixel pelo método das redes neurais artificiais utilizando-se apenas dos dados espectrais.

Após esta etapa, se fez necessária a binarização da imagem temática, já que para a posterior análise da forma dos segmentos há a necessidade de se conhecer os limites dos objetos presentes, e estes estarem mais definidos.

3.2 Pós-Processamento com Morfologia matemática

De acordo com FACON (1993), o princípio da morfologia matemática consiste em extrair informações relativas à geometria e à topologia de um conjunto desconhecido (uma imagem), pela transformação através de outro conjunto completamente definido, denominado de elemento estruturante.

O operador de morfologia matemática utilizado neste trabalho foi a abertura, que consiste em uma erosão seguida de uma dilatação, procedimento este necessário quando se deseja separar segmentos conectados.

A Figura 7 apresenta o resultado da imagem classificada binarizada, após o processo de abertura, onde a mesma apresenta apenas os padrões onde apresentam confusão na classificação, ou seja, areia, asfalto e construções.



Figura 7 – Resultado do processo de abertura aplicada à imagem binarizada.

3.3 Rotulação dos componentes conexos

A rotulação de componentes conexos tem por finalidade identificar todos os pixels que formam uma região em uma imagem binária. O reconhecimento dos componentes conectados pode ser dividido em três fases:

1. numeração dos pixels não nulos;
2. identificação dos componentes conexos, e;
3. renumeração das regiões.

A primeira fase numera, em ordem crescente, todos os pixels com nível de cinza igual a 255 (feições em estudo) a partir do canto superior esquerdo da imagem binária, varrendo cada linha da esquerda para a direita. A Figura 8 apresenta o exemplo de uma imagem ao final da execução desta fase.

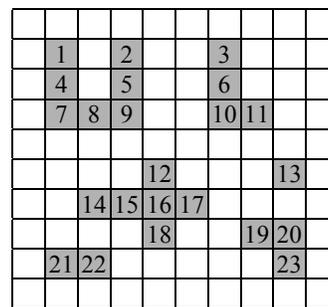


Figura 8 – Numeração dos pixels.

Após a numeração dos pixels não nulos é feito o reconhecimento dos componentes conexos, atribuindo a todos os pixels de cada região o menor valor. Assim, ao final desta fase, tem-se todos os pixels de cada região com o mesmo número, como pode ser verificado através da Figura 9.

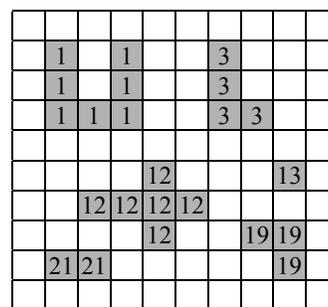


Figura 9 – Rotulação das regiões.

A última fase de reconhecimento dos componentes conexos é a renumeração das regiões, transformando a numeração existente (1, 3, 12, 13, 19, 21) em uma seqüência contínua (1, 2, 3, 4, 5, 6). A Figura 10 ilustra o resultado final do processo de rotulação dos componentes conexos.

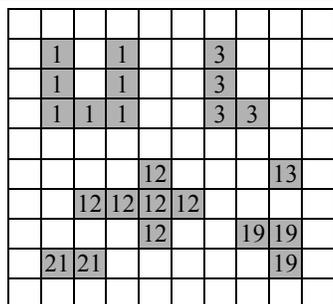


Figura 10– Regiões numeradas.

3.4 Descrição dos segmentos

Os agrupamentos resultantes de pixels segmentados ou resultantes de classificação são usualmente representados e descritos em um formato apropriado para o processamento subsequente. A representação de uma região envolve duas escolhas:

- através da representação da região em termos de suas características externas (sua fronteira);
- em termos de suas características internas (pixels que compõem a região).

Geralmente, uma representação externa é escolhida quando a atenção primária estiver voltada para as características de forma. Na representação interna, são voltadas às propriedades como cor e textura (GONZALES; WOODS, 2000).

3.5 Classificação dos segmentos usando redes neurais artificiais

De acordo com HAYKIN (2001), o trabalho em Redes Neurais Artificiais (RNA's), tem sido motivado desde o começo pelo reconhecimento de que o cérebro humano processa informações de uma forma inteiramente diferente do computador digital convencional. O cérebro é um sistema de processamento de informação altamente complexo, não-linear e paralelo. Ele tem a capacidade de organizar seus constituintes estruturais, conhecidos por neurônios, de forma a realizar certos processamentos (p. ex., reconhecimento de padrões, percepção e controle motor) muito mais rápido que o mais ágil computador hoje existente.

NELSON & ILLINGWORTH (1990), definem as RNAs como sendo técnicas inovadoras de processamento de informações, que têm como objetivo básico, simular, em computadores, o funcionamento do sistema nervoso biológico.

Conforme DYMINSKI (2000), uma rede neural é constituída por diversos neurônios. Diversos neurônios são conectados entre si para se formar uma rede neural, sendo que a maneira como os mesmos são dispostos caracteriza a arquitetura da rede.

Arquiteturas neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior.

Usualmente as camadas são classificadas em três grupos:

- Camada de Entrada: onde os padrões são apresentados à rede;
- Camadas Intermediárias ou Escondidas: onde é feita a maior parte do processamento, através das conexões ponderadas; podem ser consideradas como extratoras de características;
- Camada de Saída: onde o resultado final é concluído e apresentado.

O número de neurônios e camadas em uma dada estrutura, é função do problema a ser resolvido. A camada de saída, em um problema de classificação de dados, pode representar o número de classes para as quais os padrões podem ser designados. O número de neurônios e camadas em uma dada estrutura, é função do problema a ser resolvido. A camada de saída, em um problema de classificação de dados, pode representar o número de classes para as quais os padrões podem ser designados. Na classificação de imagens de satélite, por exemplo, se os padrões de entrada estão localizados em uma área onde há a existência de três classes, "Vegetação", "Área Urbana" e "Água", três neurônios de saída serão necessários (NIHISDA, 1998). O número de neurônios de entrada é função do número de dados considerados na classificação, no caso do presente trabalho o número de entradas será a soma das entradas espectrais e dos dados espaciais (descritores de forma utilizados).

O tipo de rede chamada de "multi-camadas feedforward" caracteriza-se por apresentar neurônios, total ou parcialmente conectados por sinapses (pesos), organizados em camadas. As entradas alimentam a rede e são processadas até alcançarem a camada de saída, sem realimentação. Por isso são caracterizadas como feedforward (alimentação e propagação para frente). É o tipo de rede mais utilizado em aplicações de diversas áreas da engenharia (DYMINSKI, 2000).

No presente trabalho utilizou-se uma rede do tipo *feedforward* com o algoritmo *backpropagation*, já que os mesmos são os mais recomendados pela bibliografia no reconhecimento de padrões.

Para os primeiros experimentos para a classificação dos segmentos, utilizou-se a área, perímetro, coeficiente de compacidade e a razão área e perímetro como parâmetros descritores da forma. Utilizou-se de seis segmentos para cada padrão como amostras de treinamento, sendo que o resultado obtido foi o apresentado através da Figura 11 abaixo.

Pode-se observar comparando com a imagem da Figura 6 (que apresenta o resultado da classificação puramente espectral e onde observa-se ma certa confusão entre os padrões areia e construções), que após a utilização de parâmetros de forma estes foram melhor discriminados. Após a classificação observou-se a discriminação de 31 construções que antes foram consideradas como o padrão "areia", na classificação puramente espectral apresentada na Figura 6.

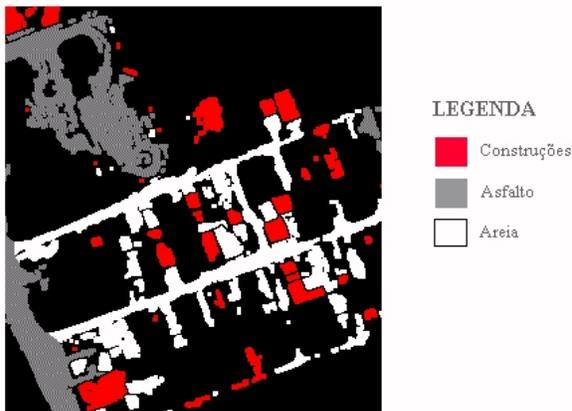


Figura 11 – Resultado da classificação utilizando os descritores de forma e das redes neurais artificiais como classificador.

4 CONSIDERAÇÕES FINAIS

Devido ao surgimento dos sensores com alta resolução espacial, como o IKONOS II com uma resolução espacial de 1m, e muitos outros sensores recém desenvolvidos como o QUICKBIRD com resolução espacial de 61cm, muitos detalhes como construções, estradas, árvores como também outros componentes que podem ser claramente identificados nestas imagens de alta resolução. Com isto, os métodos tradicionais de classificação de imagens baseados em pixels não oferecem resultados satisfatórios.

Através da análise dos resultados preliminares obtidos com a classificação utilizando parâmetros de forma como um dado auxiliar como também a utilização das redes neurais artificiais, pode-se concluir que os classificadores tradicionais *pixel-a-pixel* apenas utilizam as informações espectrais, e este fato mostra-se como uma limitação na utilização dos mesmos. Com a inserção dos novos sensores de alta resolução, onde maiores detalhes da paisagem urbana podem ser identificados, os métodos de classificação orientados ao objeto passam a ter maior importância, já que os mesmos consideram além dos atributos espectrais as relações espaciais entre os pixels.

A análise de forma e tamanho é uma poderosa ferramenta para a discriminação de objetos que possuem a mesma aparência espectral, isto se pode observar através do resultado obtido da Figura 11

A utilização de Redes Neurais Artificiais emerge como uma alternativa vantajosa aos classificadores baseados em conceitos estatísticos, já que se podem obter resultados satisfatórios utilizando-se de um número mínimo de amostras para que a mesma faça a generalização. A flexibilidade dos algoritmos de classificação baseados em redes neurais permite integrar variáveis diferentes na identificação de objetos, como por exemplo de características espectrais e espaciais.

REFERÊNCIAS

BÄSSMAN, H.; KREYSS, J. **Bildverarbeitung Ad Oculus**. Heidelberg Springer, 1998.

CHUVIECO, E. **Fundamentos da Teledetección Espacial**. Ediciones Rialp, S. A. Madrid, 1990.

DE COLA, L. Fractal analysis of a classified landsat Scene. **Photogrammetric Engineering and Remote Sensing**. v.55, n. 5, p. 601-610, 1989.

DYMINSKI, A S. **Análise de Problemas Geotécnicos Através de Redes Neurais**. Rio de Janeiro, 2000. Tese (Doutorado em Geotecnia) - Curso de Pós-Graduação em Engenharia Civil, Universidade Federal do Rio de Janeiro.

FACON, J. **Processamento e Análise de Imagens**. Universidad Nacional de Córdoba, Argentina, 1993.

FRANKLIN, S.E.; WILSON, B.A. A Three Stage Classifier for Remote Sensing of Mountain Environment. **Photogrammetric Engineering and Remote Sensing**. v. 58, n. 4, p. 449-454, 1992.

GONZALES, R.C.; WOODS, R.E. **Processamento de Imagens Digitais**. Edgard Blücher Ltda. São Paulo, 2000.

HAYKIN, S. **Redes Neurais. Princípios e prática**. Editora Bookman. Porto Alegre, 2001.

HUTCHINSON, F.C. Techniques for Combining Landsat and Ancillary Data for Digital Classification Improvement. **Photogrammetric Engineering and Remote Sensing**. v. 48, n. 1, p. 123-130, 1982.

LAGRO, J.J. Assessing patch shape in Landscape Mosaics. **Photogrammetric Engineering and Remote Sensing**. v. 57, n. 3, p. 285-293, 1991.

LAM, N.S.N. Description and Measurement of Landsat TM Images using Fractais. **Photogrammetric Engineering and Remote Sensing**. v. 56, n. 2, p. 187-195, 1990.

LILLESAND, T.M.; KIEFER, R.W. **Remote Sensing and Image Interpretation**. John Wiley & Sons. New York, USA, 1994.

MASCARENHAS, N.D.A.; VELASCO, F.R.D. **Processamento Digital de Imagens**. Editora Kapelusz. Buenos Aires, 1989.

MARQUES, O F.; VIEIRA, H. N. **Processamento Digital de Imagens**. Editora BRASPORT. Rio de Janeiro, 1999.

MEYER, M. WERTH. Satellite Data: Management Panacea or Potencial Problem? **Journal of Forestry**. v. 88, n. 09, p. 10-13, 1990.

NELSON, M.M.; ILLINGWOTH, W.T. **A Practical Guide to Neural Networks**. Addison-Wesley Publishing Company, Inc. USA, 1991.

PALMER, M.W. Fractal geometry: a tool for describing spatial patterns of plant communities. **Photogrammetric Engineering and Remote Sensing**. v. 75, p. 91-102, 1988.