

Uso de Algoritmos Genéticos na Seleção de Atributos para Classificação de Regiões

Joelma Carla Santos, João Ricardo de F. Oliveira, Luciano V. Dutra

Instituto Nacional de Pesquisas Espaciais (INPE) - São José dos Campos – SP - Brasil

{joelma, joao, dutra}@dpi.inpe.br

Abstract. *The technological advances about remote sensing allows a better identification of urban targets in the images. The aim of this work is to classify automatically the urban spaces applying feature extraction and selection techniques, in high resolution images. To classify the road network and others urban components, some shape features that permit to recognize different objects with analogous spectral characteristics will be implemented. To maximize the classification accuracy and decrease processing costs, the feature selection will be done with genetic algorithms and exhaustive search using gaussian maximum-likelihood.*

Resumo. *O avanço tecnológico dos sensores remotos possibilita a geração de imagens com maior discriminação entre os alvos urbanos. O objetivo deste trabalho é classificar automaticamente o espaço urbano, aplicando técnicas de extração e seleção de atributos em imagens de alta resolução. Para classificar a malha viária e outros componentes urbanos serão implementados alguns atributos de forma que permitem reconhecer objetos distintos espectralmente semelhantes. Para maximizar a exatidão da classificação e diminuir o custo de processamento, a seleção de atributos será feita pelos algoritmos genéticos e pela busca exaustiva por máxima verossimilhança gaussiana.*

1. Introdução

Os avanços tecnológicos cada vez maiores na área de sensores remotos têm gerado imagens que permitem uma maior discriminação de alvos da superfície terrestre. Com esta possibilidade, torna-se maior o número de aplicações dos dados de sensoriamento remoto para estudos relativos ao sistema urbano [Donnay et al. 2001] e aumenta-se a precisão das informações obtidas a partir deles [Souza et al. 2003].

Para tratamento e obtenção de informações das imagens são usados sistemas de processamento de imagens que abrangem operações como aquisição, armazenamento, processamento e visualização. A operação de processamento pode envolver várias etapas como pré-processamento, segmentação, extração de atributos, treinamento, seleção de atributos e classificação [Marques Filho e Vieira Neto 1999]. O foco deste trabalho é direcionado às etapas de extração e seleção de atributos.

Os algoritmos de classificação *pixel a pixel* usam de forma individual a informação espectral de cada *pixel* na busca por regiões homogêneas. Já a classificação

por regiões baseia-se no princípio de dividir a imagem em pequenos segmentos, considerados objetos ou regiões, que são extraídos da imagem original por meio de técnicas de segmentação. Tais objetos são posteriormente analisados isoladamente, permitindo a inclusão de atributos espaciais, como forma e textura, que não poderiam ser considerados numa análise *pixel a pixel* [Ribeiro et al. 2002]. A forma pode ser considerada como uma expressão do contorno dos objetos; é uma importante ferramenta para discriminar objetos de uma cena que possuem a mesma aparência espectral.

A grande dimensionalidade do espaço de atributos pode causar um alto custo de processamento e prejudicar a exatidão da análise das cenas. O termo seleção de atributos refere-se aos algoritmos que selecionam o melhor subconjunto a partir de um conjunto de atributos dado que conduza a um menor erro na classificação [Jain et al. 2000].

O sistema *Texture – A region classifier using textural measures* [Rennó et al. 1998] fornece um ambiente amigável ao usuário para extração e análise de medidas texturais de imagens, e realiza a classificação de regiões baseada na pré-seleção de medidas.

O objetivo deste trabalho é integrar ao sistema *Texture* novos atributos de forma no processo de classificação de regiões e incluir novas estratégias de seleção de atributos usando algoritmos genéticos e busca exaustiva por máxima verossimilhança gaussiana.

2. Extração de Atributos

O objetivo da extração de atributos é caracterizar medidas associadas ao objeto que se deseja extrair, de forma que estas medidas sejam similares para objetos similares e diferentes para objetos distintos [Duda 2001].

A análise da forma do objeto é de fundamental importância para estudos relacionados com o espaço urbano. Construções e asfalto mesmo sendo, algumas vezes, similares espectralmente, podem ser separados pela forma, uma vez que o asfalto possui a forma mais alongada que as construções. A seguir, são abordados os parâmetros de forma que serão utilizados nesta pesquisa.

2.1. Deficiência Convexa

A deficiência convexa “ D ” de um objeto “ O ” de uma imagem é obtida a partir do menor conjunto convexo “ H ” que contiver “ O ”. A diferença entre os conjuntos “ H ” e “ O ” é chamada deficiência convexa do objeto. A Figura 1 mostra um objeto “ O ” e sua deficiência convexa sombreada. Este atributo é atrativo quando a descrição de uma região pode basear-se em sua área e na área de sua deficiência convexa, no número de componentes de sua deficiência convexa ou na posição relativa desses componentes [Gonzales e Woods 2000].




Figura 1. Deficiência Convexa

2.2. Eixo Menor e Maior da Elipse

O atributo de forma relação eixo menor e maior da elipse descreve o grau de alongamento de uma região. Este pode ser calculado através da razão entre o eixo menor e o eixo maior da elipse que mais se ajusta ao objeto. Estes eixos podem ser obtidos através da análise por componentes principais de cada região estimando-se os autovalores (comprimento) e respectivos autovetores (direção) [Andrade e Centeno 2003].

2.3. Direção Principal

O atributo de direção principal de um objeto é a direção do autovetor correspondente ao maior dos autovalores derivados da matriz de covariância do objeto [Gonzales e Woods 2000]. A Figura 2 ilustra um objeto com sua direção principal representado pelo autovetor na cor vermelha.




Figura 2. Direção principal de um objeto

2.4. Comprimento de Fibra

O comprimento aproximado de um objeto pode ser medido através do parâmetro conhecido como Comprimento de Fibra, ou *Fiber Length*.




Figura 3. Comprimento da fibra de um objeto

Segundo Russ (1991), o comprimento do objeto pode ser estimado utilizando a área (A) e o perímetro (P) de duas maneiras:

$$FL = 0,3181 * P + (0,033012 * P^2 - 0,41483 * A)^{\frac{1}{2}}$$

$$FL = 0,5 * P - 2 * \frac{A}{P}$$

2.5. Densidade

Quanto mais um objeto se assemelha a um quadrado maior o valor de sua densidade. Segundo o manual do eCognition¹, a densidade pode ser calculada como sendo a área coberta pelo objeto dividida pelo raio usando a seguinte equação,

$$d = \frac{\sqrt{n}}{1 + \sqrt{\text{Var}(X) + \text{Var}(Y)}}$$

onde n é o número de *pixels* que forma o objeto e o raio é calculado de forma aproximada utilizando a matriz de covariância.

3. Seleção de Atributos

A seleção de atributos pode ser vista como um processo de busca onde o algoritmo usado deve encontrar o menor subconjunto de atributos com a melhor acurácia de classificação [Pappa et al. 2002b].

Quando a dimensionalidade do espaço de atributos é grande, isso pode resultar em dois tipos de problemas [Bishop 1995]:

- alto custo de processamento
- geração do fenômeno conhecido como maldição da dimensionalidade

A maldição da dimensionalidade, ou fenômeno de Hughes, está ligada à degradação na acurácia dos resultados da classificação com o aumento da dimensionalidade dos dados, mantendo constante o número de amostras de treinamento [Tadjudin e Landgrebe 1998].

Em um maior nível de abstração, a seleção de atributos pode ser dividida em duas partes: o método de busca e a função de avaliação usada para medir a qualidade dos subconjuntos [Pappa et al. 2002b]. A busca exaustiva pode ser considerada o melhor critério de busca, pois são geradas todas as combinações possíveis de atributos. Pode-se considerar também como melhor critério de qualidade o mínimo erro, onde as imagens são classificadas, considerando como melhor aquele que apresenta a maior exatidão de classificação. Adotar critérios ótimos de busca e qualidade simultaneamente são métodos “caros” computacionalmente. Possíveis soluções são adotar critérios de busca “baratos” (sub-ótimos) com critérios de qualidade “caros” (ótimos), ou critérios de busca ótimos e qualidade sub-ótimos, ou ainda critérios de busca e qualidade sub-ótimos.

O objetivo dos algoritmos de seleção de atributos é escolher o menor subconjunto que oferece a melhor classificação em conformidade com custos computacionais razoáveis.

3.1. Algoritmos Genéticos

Os algoritmos genéticos (AGs), desenvolvidos por John Holland, são métodos de busca e otimização baseados nos mecanismos de evolução dos seres vivos [Goldberg

¹ eCognition – Object Oriented Image Analysis: Software utilizado para classificação de imagens. Homepage: <http://www.definiens-imaging.com/>

1989]. Estes algoritmos baseiam-se na teoria do naturalista Charles Darwin (1859), que afirma que os indivíduos mais adaptados ao seu ambiente são os que possuem maior chance de sobreviver e gerar descendentes.

O primeiro passo de um AG é a geração de uma população inicial de indivíduos caracterizados por seus cromossomos que podem ser vistos como possíveis soluções do problema. Durante o processo evolutivo, esta população é avaliada e cada cromossomo recebe uma nota, refletindo sua habilidade de adaptação à determinado ambiente. Os cromossomos mais aptos são selecionados e os menos aptos são descartados (Darwinismo). Os indivíduos selecionados sofrem cruzamentos e mutações, gerando descendentes para a próxima geração. Este processo é repetido até que uma solução satisfatória seja encontrada [Goldberg 1989; Lacerda e Carvalho 1999].

O método da Roleta é uma maneira de selecionar indivíduos, onde segundo Goldberg (1989), cada indivíduo possui uma fatia da roleta proporcional à sua adaptação. A cada giro da roleta um indivíduo é selecionado, tendo maior chance aqueles que possuem as maiores fatias.

O cruzamento consiste basicamente em misturar o material genético de dois indivíduos da população, produzindo dois novos indivíduos (filhos) que herdam características dos pais.

A operação de mutação evita a convergência prematura do algoritmo, introduzindo na busca novas regiões do espaço de soluções [Oliveira 1998]. Esta consiste em inverter os valores de bits, ou seja, mudar o valor de 1 para 0 ou de 0 para 1.

A função de avaliação é utilizada para determinar a qualidade de uma solução candidata [Pappa 2002a]. Ela oferece ao AG uma medida da aptidão de cada indivíduo da população [Goldberg 1989]. A escolha de uma função de avaliação apropriada é um passo essencial para o sucesso de uma aplicação de AG [Vafaie e De Jong 1992, 1993; Oliveira 1998].

3.2. Busca Exaustiva

Um outro método para a realização da seleção de atributos é através da busca exaustiva. Este método gera todas as combinações possíveis de atributos para encontrar a solução desejada. Algumas vezes, este método pode ser inviável computacionalmente devido ao seu tempo de processamento crescer exponencialmente com o aumento do número de atributos [Pappa 2002a].

4. Metodologia

O sistema *Texture* foi desenvolvido na linguagem IDL (*Interactive Data Language*) com o uso de funções do ENVI (*Environment for Visualizing Images*). Neste trabalho, pretende-se integrar ao sistema *Texture* métodos de seleção de atributos usando algoritmos genéticos e busca exaustiva pelo mínimo erro usando máxima verossimilhança gaussiana. Também serão desenvolvidos os atributos de forma descritos anteriormente. Serão utilizadas imagens do satélite Ikonos com 1 m de resolução de áreas urbanas de São José dos Campos – SP. Primeiramente serão utilizadas imagens sintéticas que simulam formas de objetos presentes nas imagens Ikonos, principalmente o arruamento. Após a realização de testes nas imagens sintéticas,

estes também serão aplicados às imagens reais. Algumas imagens Ikonos com alguns de seus padrões sintéticos são mostradas na Figura 4.

No processo de seleção de atributos usando algoritmos genéticos, o cromossomo será representado por um vetor, onde cada elemento será um dígito binário (0 ou 1) representando a presença ou ausência do i -ésimo atributo [Vafaie 1992,1993, Huber e Dutra 2000]. Para seleção dos indivíduos será adotado o método da roleta. A população inicial será gerada de forma aleatória ou com ajuda do método da escolha fixa já existente no sistema *Texture* [Oliveira et al 2005]. A função de avaliação será definida como a maior distância média *Jeffreys-Matusita* (JM) entre os pares de classes.

A distância JM expressa medidas estatísticas de separabilidade entre duas distribuições [Dutra e Huber 1999]. A distância JM entre as classes k e i é dada por:

$$JM_{ki} = \sqrt{2(1 - e^{-B_{ki}})} \quad JM \in [0, \sqrt{2}]$$

onde B_{ki} representa a distância de Bhattacharyya entre as classes k e i dada por:

$$B_{ki} = \frac{1}{8} (\mu_k - \mu_i)^t \left[\frac{\Sigma_k + \Sigma_i}{2} \right]^{-1} (\mu_k - \mu_i) + \frac{1}{2} \ln \frac{\left| \frac{\Sigma_k + \Sigma_i}{2} \right|}{\sqrt{|\Sigma_k| |\Sigma_i|}}$$

onde Σ_k e Σ_i são as matrizes de covariância das classes k e i , μ_k e μ_i são os respectivos vetores de média.

As estratégias usadas neste trabalho para finalizar a execução do algoritmo genético serão: por um número máximo de gerações fornecido pelo usuário, ou quando a aptidão média ou do melhor indivíduo não apresentar melhoras significativas após um determinado número de gerações.

Para a seleção de atributos também será implementada a busca exaustiva pelo mínimo erro através da Máxima Verossimilhança Gaussiana (Maxver). O melhor subconjunto será aquele que apresentar a maior acurácia total na classificação realizada pelo Maxver. A acurácia total é uma das maneiras de se avaliar a acurácia da classificação [Dutra e Huber 1999].

A classificação por máxima verossimilhança gaussiana usa a ponderação das distâncias entre médias dos níveis digitais das classes, utilizando parâmetros estatísticos. É baseada na forma da probabilidade Bayseana [Tso e Mather 2001].

Para determinar a qual classe uma determinada região com um vetor espectral x (vetor dos valores de intensidade em cada banda espectral) pertence, deve-se avaliar a probabilidade de x pertencer à cada uma das classes. A região é atribuída à classe de maior probabilidade. A partir das amostras de treinamento é possível estimar a distribuição de probabilidade de cada classe.

O Maxver utiliza o conceito de limiar de decisão. Estes são traçados a partir dos pontos onde os contornos de igual probabilidade entre duas classes contíguas se cruzam [Crósta, 1999]. Uma região localizada na área de cruzamento de probabilidades entre

duas classes, apesar de também pertencer à classe z , será classificada como classe y , devido ao limite de decisão estabelecido.

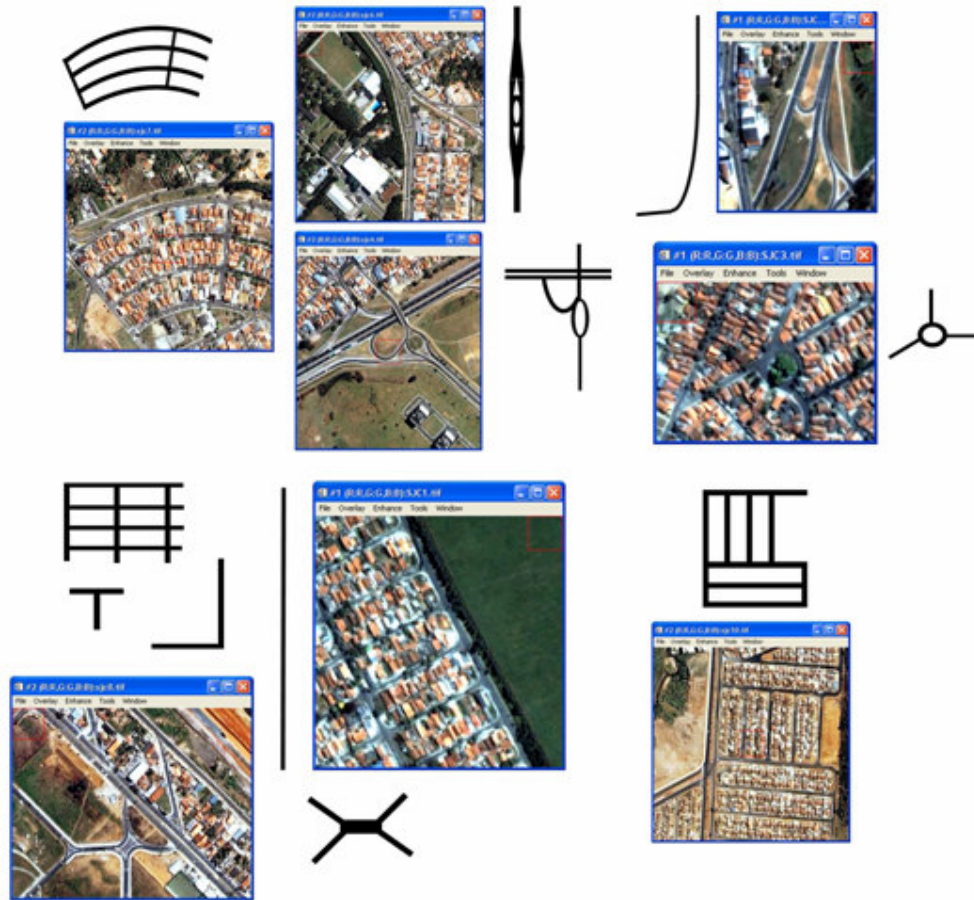


Figura 4. Imagens Ikonos com alguns de seus padrões sintéticos

5. Resultados Esperados

Espera-se, com a implementação dos atributos de forma, obter a classificação correta de objetos urbanos espectralmente semelhantes, principalmente o arruamento. Com os métodos de seleção de atributos pretende-se diminuir a dimensionalidade dos dados, evitando a perda de acurácia na classificação.

Espera-se também que os métodos de seleção e extração de atributos propostos, integrados aos já existentes no sistema *Texture*, transforme este sistema em uma ferramenta importante para o mapeamento do espaço urbano, servindo como suporte para o planejamento e administração municipal.

References

Andrade, A. F. e Centeno, J. A. S. (2003). Integração de Informações Espectrais e de Forma na Classificação de Imagens com Redes Neurais. In *Boletim de Ciências Geodésicas*, 9(2):217-231.

- Bishop, C. M. (1995), *Neural Networks for Pattern Recognition*. Oxford University Press.
- Crósta, A. P. (1999), *Processamento Digital de Imagens de Sensoriamento Remoto*, IG/UNICAMP.
- Darwin, C. (1859) “The Origin Of Species by Means of Natural Selection”, In: *The Descent Of Man and Selection in Relation to Sex*. Encyclopaedia Britannica, INC. The University of Chicago. (1952) Chicago.
- Donnay, J. P.; Barnsley, M. J. and Longley, P. A. (2001) “Remote Sensing and Urban Analysis”, In: *Remote Sensing and Urban Analysis*, Edited by Donnay, J. P.; Barnsley, M. J.; Longley, P. A. Taylor & Francis, London.
- Duda, R. O; Hart, P. E. and Stork, D. G. (2001), *Pattern Classification*, Wiley, 2th edition.
- Dutra, L. V. and Huber, R. (1999). Feature extraction and selection for ERS-1/2 InSAR classification. In *Int. J. Remote Sensing*, 20(5): 993-1016.
- Goldberg, D. E. (1989), *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley.
- Gonzalez, R. C. e Woods, R. E. (2000), *Processamento de Imagens Digitais*. Editora Edgard Blucher Ltda.
- Huber, R. and Dutra, L. V. (2000) Classifier Combination and Feature Selection for Land-Cover Mapping From High-Resolution Airbone Dual-Band SAR Data. In: 4th World Conference on Systemics , Cybernetics and Informatics (SCI2000), Orlando, v.V p.370-375.
- Jain, A. K., Duin, R. P. W. and Mao, J. (2000). Statistical Pattern Recognition: A Review. In *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(1):4-37.
- Lacerda, E.G.M e Carvalho, A.C.P.L. (1999) “Introdução aos algoritmos genéticos”, In: *Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais*. Editado por Galvão, C.O., Valença, M.J.S. Ed. Universidade/UFRGS: Associação Brasileira de Recursos Hídricos. p. 99-150. (Coleção ABRH de Recursos Hídricos; 7.). Porto Alegre.
- Marques Filho, O. e Vieira Neto, H. (1999). *Processamento Digital de Imagens*, Brasport.
- Oliveira, J. A.; Dutra, L. V. e Rennó, C. D. (2005). Aplicação de Métodos de Extração e Seleção de Atributos para Classificação de Regiões. In *Anais XII Simpósio Brasileiro de Sensoriamento Remoto*, Goiânia, GO, p. 4201-4208.
- Oliveira, J. R. F. (1998) O uso de algoritmos genéticos na decomposição morfológica de operadores invariantes em translação aplicados a imagens digitais. (INPE-10462-TDI/929). Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

- Pappa, G. L. (2002a) Seleção de Atributos Usando Algoritmos Genéticos Multiobjetivos. Dissertação (Mestrado em Informática Aplicada) - Pontifícia Universidade Católica do Paraná. Curitiba.
- Pappa, G. L.; Freitas, A. A. and Kaestner, C. A. A. (2002b) A Multiobjective Genetic Algorithm for Attribute Selection. In *Proc. 4th Int. Conf. on Recent Advances in Soft Computing (RASC-2002)*, Nottingham Trent University. p. 116-121.
- Rennó, C. D.; Freitas, C.C. and Frery, A. C. (1998). A system for region image classification based on textural measures. In *Anais II Jornada Latino-Americana de Sensoriamento Remoto por Radar: Técnicas de Processamento de Imagens*. Santos, SP, p. 159-164.
- Ribeiro, S. A.; Santos, D. R. e Centeno, J. S. (2002). Aplicação da Metodologia de Dados Orientado a Objeto na Classificação de uma Área Urbanizada, Utilizando uma Imagem Digital Obtida por meio da Tecnologia do Laser Scanner. In: *Anais I Simpósio Brasileiro de Geomática*. Presidente Prudente, SP.
- Russ, J. C. (1991) *Computer-Assisted Microscopy The Measurement and Analysis of Images*, Plenum Press.
- Souza, I. M.; Pereira, M. N.; Fonseca, L. M. G. e Kurkdjian, M. L. N. O. (2003). Mapeamento do Uso do Solo Urbano através da Classificação por Regiões Baseada em Medidas Texturais. In *Anais XI Simpósio Brasileiro de Sensoriamento Remoto*, Belo Horizonte, p. 1967-1968.
- Tadjudin, S. and Landgrebe, D. A. (1998) "Classification of High Dimensional Data with Limited Training Samples". TRECE 98-8, School of Elec. And Comp. Eng., Purdue University.
- Tso, B and Mather, P. M. (2001) *Classification Methods for Remotely Sensed Data*, Taylor & Francis.
- Vafaie, H. and De Jong, K. (1992). Genetic Algorithms as a Tool for Feature Selection in Machine Learning. In *Proceedings of International Conference on Tools with Artificial Intelligence*, Arlington, p. 200-204.
- Vafaie, H. & De Jong, K. (1993) "Improving the Performance of a Rule Induction System Using Genetic Algorithms". In: *Machine Learning: A Multistrategy Approach*, Edited by R.S. Michalski and G. Tecuci, San Mateo, CA: Morgan Kaufmann.