

Classificação automática de cobertura do solo urbano em imagem IKONOS: Comparação entre a abordagem pixel-a-pixel e orientada a objetos

Carolina Moutinho Duque de Pinho
Flávia da Fonseca Feitosa
Hermann J. H. Kux

Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12201-970 - São José dos Campos - SP, Brasil
carolina@dsr.inpe.br, flavia@dpi.inpe.br, hermann@dsr.inpe.br

Abstract. The improvement of spatial and radiometric resolution in satellite images has introduced some challenges in urban remote sensing. Due to the large spectral variation in urban areas, the most important of these challenges is to obtain a proper distinction among different urban targets. The traditional algorithms of classification with per-pixel approach have not been successful in this purpose. Hence, tests of new methods are required. This paper presents a comparison between two methods: MAXVER, a traditional per-pixel approach, and the oriented object analysis, a region-based approach. The latter method has the advantage of using not only spectral attributes, but also geometrical and relational attributes for the classification. An IKONOS image of Esplanada, a neighborhood of São José dos Campos (SP, Brazil), was used in the experiments.

Palavras-chave: São José dos Campos-SP, land-cover, automatic classification, high resolution image, IKONOS, São José dos Campos-SP, cobertura do solo, classificação automática, imagem de alta resolução, IKONOS.

1. Introdução

A recente evolução dos níveis de resolução espacial em dados de sensoriamento remoto orbital tem ampliado a capacidade de discriminação dos alvos. Uma das áreas privilegiadas com este tipo de imagem é o sensoriamento remoto urbano, que apesar de já dispor de fontes de informação em alta resolução espacial (as fotografias aéreas métricas), ressentia-se com a inexistência de um tipo de dado que reunisse alta resolução espacial com alta resolução radiométrica. A combinação destas duas características permite a detecção dos elementos que compõem o espaço urbano e apresenta grande aplicabilidade para mapeamentos de cobertura e uso do solo urbano com o auxílio de classificadores automáticos.

Contudo, a preocupação em obter um maior aproveitamento destas imagens de alta-resolução impõe novos desafios. As tradicionais análises por pixel tornam-se limitadas em imagens que captam detalhes de cenas muito heterogêneas e com grande variação interna das classes. Nestes casos, é comum a sobreposição de classes no espaço de atributos, o que dificulta o processo de classificação. Surge, portanto, a necessidade de exploração de ferramentas alternativas que não se limitem apenas a atributos espectrais. Entre estas ferramentas, destaca-se a análise orientada a objetos, que permite a inserção do conhecimento do analista e a utilização de parâmetros de cor, forma, textura e relações de vizinhança na classificação de imagens.

Este trabalho tem como objetivo a experimentação e comparação das classificações MAXVER e orientada a objetos sobre uma imagem de alta resolução IKONOS da cidade de São José dos Campos. Os resultados obtidos foram avaliados quanto à adequação para a distinção de alvos no espaço intra-urbano.

2. Análise de Imagens Orientada a Objetos

Objetos são feições do terreno que podem ser reconhecidas no domínio da imagem. A análise orientada a objetos requer um procedimento preliminar de segmentação para a criação dos

objetos. Após este procedimento, é necessária a definição de classes e de suas inter-relações (rede semântica), a caracterização destas classes através de descritores e, finalmente, a classificação da imagem.

2.1 Segmentação multi-resolução: *Fractal Net Evolution Approach* (FNEA)

Em uma classificação orientada ao objeto, a etapa de segmentação multi-resolução é fundamental, pois é ela que delimita os objetos que serão classificados em seus respectivos níveis de detalhe.

A segmentação multi-resolução parte do pressuposto de que as informações contextuais são importantes e, por isto, a interpretação de uma cena deve considerar não apenas a dimensão espectral, como também a dimensão espacial. Para tanto, é necessário que o processo de segmentação seja moldado em função da resolução da imagem e da escala esperada para os objetos (Antunes, 2003).

O conceito de segmentação multi-resolução introduzido por Baatz e Schäpe (2000) utiliza a noção de evolução de rede fractal (FNEA), na qual a imagem de sensoriamento remoto é considerada como de natureza fractal. A segmentação da imagem resulta em segmentos ou objetos que, baseados em parâmetros espectrais e de forma, podem ser reagrupados em objetos maiores denominados super-objetos (por exemplo, *lotes* podem ser considerados sub-objetos do super-objeto *quadra*). Estes super-objetos possuem relações com os segmentos que os constituem em um nível hierárquico mais baixo (Blaschke e Hay, 2002).

O método FNEA utiliza técnicas de segmentação baseadas na estrutura de orientação a objetos. Ao contrário dos métodos fundamentados em pixels, a segmentação da imagem extrai objetos de interesse na escala desejada. Em cada escala de segmentação, a importância relativa dos parâmetros espectrais e de forma é definida através de pesos que variam entre 0 e 1. A segmentação pode incluir ainda alguma informação temática importada de um SIG.

Ao final da segmentação, obtém-se uma estrutura hierárquica que representa a informação de dados simultaneamente em diferentes resoluções. Os objetos estão em rede de vizinhança e hierarquia: cada objeto reconhece os seus vizinhos, sub-objetos e super-objetos.

2.2 Rede Semântica

A rede semântica é uma forma de representação gráfica do conhecimento através da conexão entre arcos e nós (Sowa, 2000 *apud* Antunes, 2003). Os nós são os conceitos ou categorias relativos a um determinado conhecimento e os arcos explicitam as relações entre os nós.

2.3 Classificação

Após a definição dos objetos (segmentação) e da rede semântica utilizada na estruturação das classes, a classificação dos objetos pode ser realizada. Neste processo, dois fatores devem ser levados em consideração: os descritores adotados para a diferenciação de cada classe e o classificador a ser utilizado.

Os descritores são utilizados na caracterização das classes e equivalem a relações matemáticas capazes de exprimir os atributos dos objetos. Como exemplo de descritor, pode-se citar a *densidade* do objeto, que consiste na razão da área que cobre um objeto pelo raio da circunferência circunscrita ao mesmo.

O classificador adotado neste trabalho utiliza regras *fuzzy* de pertinência para associar os objetos às classes. Assim, desaparece a tradicional noção determinística de que um objeto pertence ou não pertence a uma determinada classe. Utilizando regras *fuzzy*, um objeto pode estar associado a várias classes com diferentes graus de pertinência. O grau de pertinência varia de 0 (não pertence) a 1 (pertence) e a classe considerada é aquela cujo grau de

pertinência é maior. Por exemplo, um objeto pode apresentar o grau de pertinência 0,8 para telha cerâmica e 0,6 para a classe solo exposto. Neste caso, o objeto seria classificado como telha cerâmica, embora seu elevado grau de pertinência para duas classes distintas o tenha transformado num objeto de baixa estabilidade.

3. Material Utilizado

O trabalho foi realizado sobre duas imagens IKONOS do bairro Esplanada em São José dos Campos-SP adquiridas em 10/09/2000, uma pancromática com resolução espacial de 1m e outra multiespectral com resolução de 4m e com quatro bandas: banda 1 (azul), banda 2 (verde), banda 3 (vermelho) e banda 4 (infravermelho próximo). A escolha desta área-piloto é justificada pela horizontalidade e homogeneidade do bairro, o que diminui a quantidade de sombras e facilita a classificação automática.

Os materiais utilizados para o processamento da imagem foram:

- *Software* ENVI 3.6, para a preparação da imagem e classificação pixel-a-pixel (MAXVER);
- *Software* e-Cognition 3 (*trial version*), para a análise orientada a objetos.
- Arquivo vetorial do tipo *shapefile* com o eixo de ruas da área teste.

4. Método

O desenvolvimento deste trabalho foi efetuado nas seguintes etapas: preparação da imagem, estruturação de uma rede semântica, seleção de amostras de treinamento, classificação MAXVER, classificação orientada ao objeto e avaliação dos resultados.

4.1 Preparação da imagem

Dois processos de transformação foram realizados sobre as imagens: fusão IHS e NDVI. O objetivo da fusão foi otimizar a informação multiespectral e a boa resolução espacial da banda pancromática, o que viabiliza uma melhor identificação dos alvos urbanos. Foram efetuadas duas fusões: na primeira delas, a imagem pancromática foi fundida com as bandas 1, 2 e 3, e na segunda, com as bandas 2, 3 e 4. As bandas 3 e 4 resultantes da fusão foram empregadas na geração da imagem NDVI, utilizada na classificação orientada a objetos para diferenciar a classe vegetação das demais classes de cobertura do solo.

4.2 Estruturação da rede semântica

As classes de cobertura do solo urbano foram estipuladas e estruturadas na forma de uma rede semântica (**Figura 1**). Esta rede explicita os relacionamentos entre as classes e representa uma informação importante na classificação orientada a objetos, dado que as classes localizadas em um nível mais detalhado herdam as características das classes mais gerais.

4.3 Seleção de amostras de treinamento

As amostras foram selecionadas apenas para as classes apresentadas em negrito na rede semântica (**Figura 1**). Os resultados das classificações MAXVER e orientada a objetos foram comparados em relação à capacidade de distinção destas classes.

4.4 Classificação MAXVER

A classificação MAXVER foi efetuada no *software* ENVI sobre o produto da fusão entre as bandas 1, 2, 3 e a pancromática.

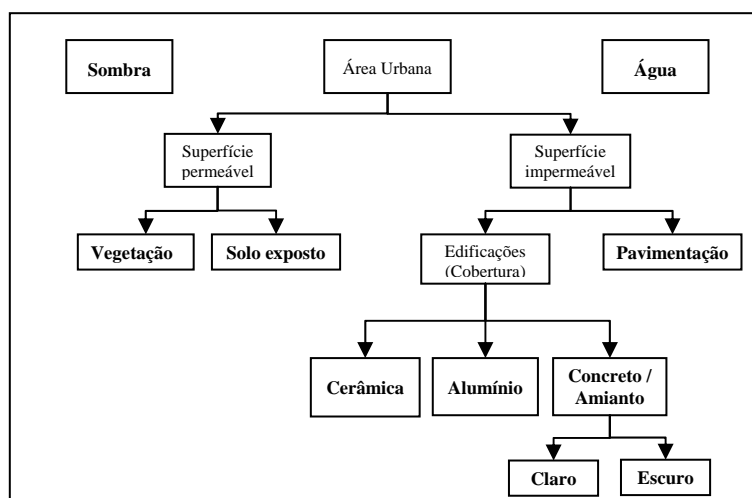


Figura 1: Rede semântica utilizada no experimento.

4.5 Classificação orientada a objetos

A classificação orientada a objetos aplicada neste trabalho divide-se em três fases: segmentação multi-resolução, definição dos descritores e classificação utilizando regras *fuzzy*.

4.5.1 Segmentação multi-resolução da imagem

A segmentação foi executada em dois níveis de escala: o primeiro mais detalhado (nível 1), e o segundo, mais geral (nível 2). No último, o objetivo foi a delimitação de objetos do tipo “quadra” e “ruas”. Esta segmentação foi feita sobre as bandas multiespectrais e priorizou a forma dos objetos (peso=0,9) ao invés das informações espectrais (peso=0,1). Para subsidiar a segmentação, o *shapefile* com o eixo de ruas da área-teste foi utilizado como informação temática.

A segmentação do nível 1 foi elaborada a partir da segmentação no nível 2, ou seja, todas as regiões do nível 1 representam sub-objetos das quadras e eixos de rua. A segmentação no nível 1 foi realizada sobre as bandas multiespectrais e sobre a imagem NDVI. Por ser mais detalhada, a segmentação no nível 1 priorizou o critério cor (peso=0,9). Os resultados das segmentações podem ser observados na **Figura 2**.

4.5.2 Definição dos descritores e classificação

Esta fase consistiu na caracterização de cada uma das classes através da seleção de atributos espectrais, de forma e de relacionamento entre super e sub-objetos. Como exemplo de descritores espectrais, pode-se citar: média e desvio padrão por banda, razão de uma banda pela soma de todas as bandas, brilho, diferença de brilho entre um objeto e seu vizinho etc. Entre os descritores de forma destacam-se: área, perímetro, comprimento, largura, densidade, razão entre comprimento e largura etc. Quanto aos de relacionamento, pode-se citar o exemplo da definição da classe pavimentação, cujo descritor mais significativo foi a restrição de que os objetos desta classe deveriam estar contidos ou contíguos ao super-objeto eixo de rua.

O primeiro passo para a definição dos descritores foi a identificação das classes que possuíam atributos muito característicos e passíveis de modelagem manual ou combinada com métodos automáticos. Estas classes foram: Vegetação, Sombra e Concreto/Amianto Claro.

A classe Vegetação foi modelada sobre os dados da imagem NDVI e com o auxílio do histograma das amostras. Já a classe Sombra apresentou resposta espectral muito baixa em

todas as bandas do visível, ou seja, baixo brilho. Desta forma, sua modelagem baseou-se nos parâmetros de média de cada banda espectral e brilho. Adicionou-se também uma restrição que impediu a classificação de áreas já indicadas como pertencentes à classe vegetação.

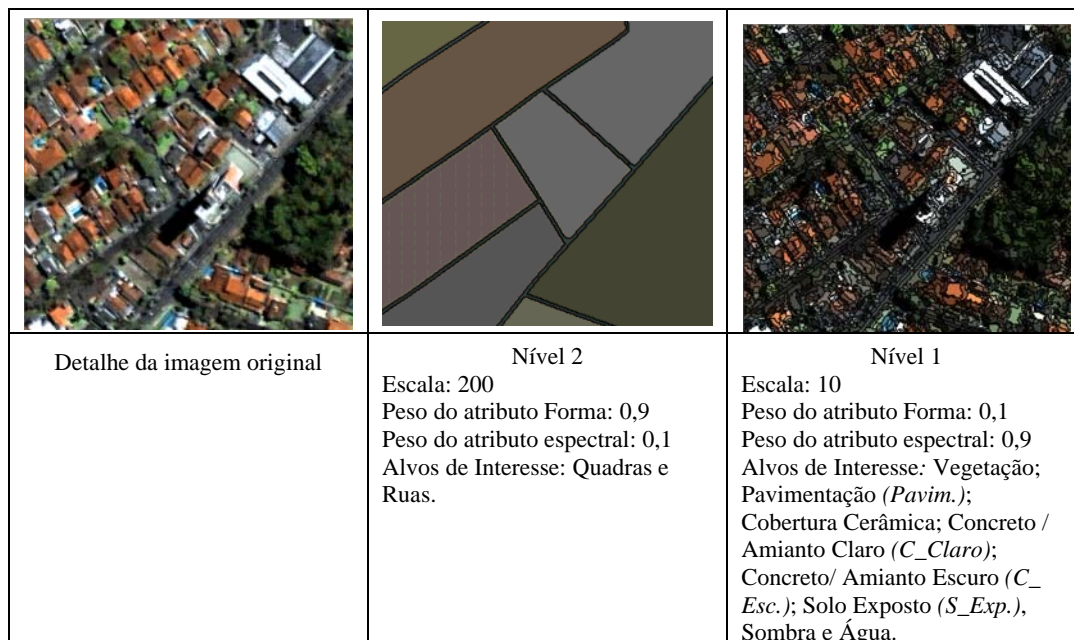


Figura 2: Exemplo da segmentação multi-resolução realizada em dois níveis.

A classe Concreto/Amianto Claro também apresenta um comportamento bem definido. Ao contrário da Sombra, esta classe apresenta altas médias nas três bandas do visível e alto brilho. A partir da análise dos histogramas (**Figura 3**), ajustou-se uma função para o brilho da classe em questão.




Figura 3: Histograma do brilho da classe Concreto/Amianto Claro


Finalizada a modelagem destas três classes, realizou-se um estudo do grau de separabilidade das demais classes a partir de atributos espectrais e espaciais. Para tanto, utilizou-se a ferramenta de otimização do espaço de atributos (*feature space optimization*). A partir de atributos escolhidos pelo analista, esta ferramenta indica a combinação com maior separabilidade entre as classes. O resultado desta análise pode ser observado através de um gráfico do grau de separabilidade de diferentes combinações de atributos e de matrizes de distância entre classes para cada combinação (**Figura 4**).

Embora o gráfico da **Figura 4** indique uma maior separabilidade para o conjunto de quatro atributos, optou-se por contemplar todas as feições espectrais através da utilização do conjunto com sete atributos. Este conjunto apresenta atributos espectrais, média e desvio padrão das três bandas do visível, e um atributo de forma, relação comprimento/largura. A partir destes atributos, funções de pertinência *fuzzy* foram modeladas automaticamente para cada classe.

Após este processo, uma classificação foi efetuada e seu resultado ainda apresentava algumas confusões na identificação de determinadas classes. Para minimizar este problema, realizou-se um refinamento nas classes que não apresentaram bons resultados através da

inserção manual de outros descritores. Foi verificado, por exemplo, que a classe Alumínio apresentava uma faixa de brilho bem discriminada, com valores superiores aos das demais classes. Por esta razão, sua diferenciação foi aprimorada através da inserção de uma função de pertinência do brilho. Porém, como a classe Concreto/Amianto Claro também possuía altos valores de brilho, uma análise dos histogramas foi efetuada para evitar a sobreposição das duas classes no espaço de atributos. Através desta análise, verificou-se que os histogramas do brilho destas classes são bastante distintos, o que permitiu a modelagem deste descritor para cada uma delas. Na **Figura 5**, observa-se a diferenciação das funções *fuzzy* de pertinência para o descritor brilho entre as classes Alumínio (à esquerda) e Concreto/Amianto Claro (à direita).

Definidos os descritores, a classificação foi realizada sobre a imagem.



	Água	Pavim	C_Esc	C_Claro	Alumínio	Vegetação	Cerâmica	S_exp
Água	0.000000	8.701085	6.800135	8.331107	2.519191	7.148217	18.508694	17.735232
Pavim	8.701085	0.000000	0.435663	48.010926	10.321486	2.595724	7.106999	29.327563
C_Esc	6.800135	0.435663	0.000000	36.918318	7.056829	1.589056	5.642487	21.646768
C_Claro	8.331107	48.010926	36.918318	0.000000	2.245619	13.972452	22.112473	11.543999
Alumínio	2.519191	10.321486	7.056829	2.245619	0.000000	4.582303	12.093799	11.946882
Vegetação	7.148217	2.595724	1.589056	13.972452	4.582303	0.000000	3.595208	12.927397
Cerâmica	18.508694	7.106999	5.642487	22.112473	12.093799	3.595208	0.000000	12.525924
S_exp	17.735232	29.327563	21.646768	11.543999	11.946882	12.927397	12.525924	0.000000

(b)

Figura 4: (a) Gráfico do grau de separabilidade das diferentes combinações de atributos e (b) matriz de distância entre as classes para um determinado conjunto de atributos.

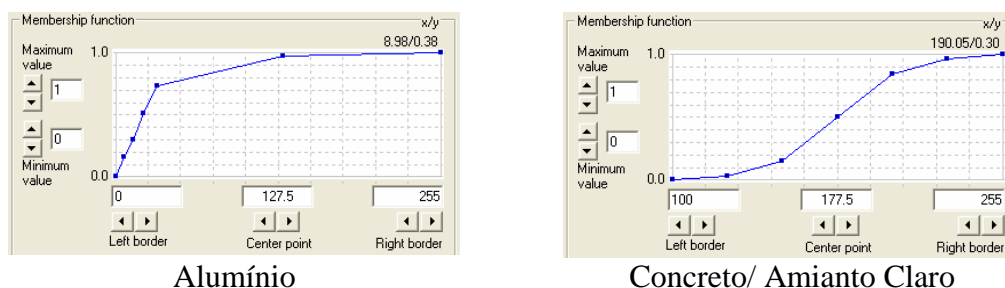


Figura 5: Funções de pertinência *fuzzy* do descritor brilho para as classes Alumínio e Concreto Amianto/Claro.

4.6 Avaliação

A avaliação dos resultados fundamentou-se em uma apreciação qualitativa do produto da classificação. Isto ocorreu devido ao programa utilizado na classificação orientada a objetos, o e-Cognition, era uma versão *trial* (demonstrativa) e não disponibilizava ferramentas de avaliação da acurácia de classificação nem de exportação dos resultados obtidos.

5. Resultados e Discussões

Os resultados das classificações MAXVER e orientada a objetos são apresentados na **Figura 6**. Por intermédio desta figura, percebe-se que a classificação MAXVER detectou melhor as

classes Vegetação e Água (piscinas). Entretanto, confundiu bastante dois pares de classes que apresentam comportamento espectral semelhantes: Cobertura Cerâmica x Solo Exposto e Pavimentação x Concreto/Amianto Escuro. Na classificação orientada a objetos, esta confusão foi minimizada em virtude da introdução de parâmetros espaciais (forma e topologia) e da utilização do dado auxiliar “eixo de ruas” durante os processos de segmentação e classificação. A classificação orientada a objetos também demonstrou uma melhor identificação da classe Sombra, o que possibilitou uma definição visual dos objetos mais refinada.




Figura 6: Resultados das classificações.

De maneira geral, a comparação entre os métodos revela uma maior preservação das formas dos alvos de interesse na classificação orientada a objetos, enquanto o resultado da classificação MAXVER apresentou uma aparência granulada.

No caso particular da classificação baseada em regras fuzzy de pertinência, a noção de que cada objeto classificado “pertence” ou “não pertence” a uma determinada classe é substituída pela idéia de que o objeto pertence “mais” ou “menos” às classes. Desta forma, é possível elaborar mapas da estabilidade da classificação, útil na identificação de objetos cuja classificação apresentou uma incerteza maior, e mapas de pertinência (**Figura 7**) que indicam os objetos onde o grau de pertinência das classes foi superior.



Figura 7: Mapa de pertinência da classificação. Em branco, estão os objetos com graus de pertinência mais elevados para as classes aos quais foram classificados.

6. Considerações Finais

Neste trabalho, foram comparadas duas abordagens diferentes para classificação de alvos urbanos em imagem de alta resolução espacial: uma pixel-a-pixel, através do classificador MAXVER, e outra orientada a objetos. Os resultados obtidos comprovaram que a segunda abordagem é uma alternativa promissora para minimizar o problema da grande variabilidade espectral inter e intra-classes nas áreas urbanas. Enquanto os classificadores tradicionais, baseados exclusivamente em dados espectrais, tornam-se limitados em áreas urbanas em virtude da sobreposição de classes em seu espaço de atributos, os classificadores orientados a objetos possibilitam a inserção dos tradicionais elementos de interpretação visual (cor, forma, tamanho, textura, padrão e contexto) na forma de descritores.

Cabe salientar, entretanto, que a capacidade de inserção do conhecimento possibilitada pela classificação orientada a objetos tende a tornar o processo de classificação mais complexo, exigindo uma especialização muito maior e uma participação mais decisiva por parte do analista.

Referências

Antunes, A. F. B. **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial**. Tese (Doutorado em Ciências Geodésicas) - Universidade Federal do Paraná, Curitiba. 2003.

Baatz, M.; Schäpe, A.. Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation. In: Strobl, J. and Blaschke, T. (Hrsg.). **Angewandte Geogr. Informationsverarbeitung XII**, Heidelberg : Wichmann, 2000.

Blaschke, T.; Hay, G. **Object-oriented image analysis and scale-space: theory and methods for modelling and evaluating multiscale landscape structure**. January, 2002. Available: <www.definiens.com/publications.pdf>. access at Oct. 15th 2004.