

Classificação de áreas de favelas a partir de imagens IKONOS: Viabilidade de uso de uma abordagem orientada a objeto

Eliane A. ESTEVAM & Erivaldo A. SILVA

Departamento de Cartografia, Faculdade de Ciências e Tecnologia - Universidade Estadual Paulista. Rua Roberto Simonsen, 305, CEP 19.060-900, Presidente Prudente, São Paulo, Brasil. E-mails: liaestevam@yahoo.com.br; silva.erivaldo@gmail.com

Recebido em 12/2008. Aceito para publicação em 05/2010.

Versão online publicada em 24/12/2010 (www.pesquisasemgeociencias.ufrgs.br)

Resumo - O crescimento das grandes cidades geralmente ocorre de forma acelerada e desorganizada, ocasionando conflitos de ordem social, econômica e de infra-estrutura, gerando, frequentemente, áreas de ocupação ilegal. Para um melhor gerenciamento dessas áreas, o gestor público necessita de informações sobre a localização delas. Estas informações podem ser obtidas por meio de mapas de uso e cobertura da terra, sendo as imagens orbitais de sensoriamento remoto uma das fontes mais tradicionais de dados para confecção destes mapas. Neste contexto, o presente trabalho testou a aplicabilidade da classificação orientada a objetos para categorizar duas áreas faveladas, levando em consideração a estrutura dos arruamentos, tamanho dos barracos, distância entre as casas, entre outros parâmetros. Essas combinações de aspectos físicos da área foram analisadas com a ajuda da imagem IKONOS II e do *software eCognition*. Áreas faveladas, contrariamente às áreas planejadas, tendem a ser desarranjadas, com ruas estreitas, casas pequenas e construídas com os mais variados materiais e sem definição de quadras. Os resultados das classificações de cobertura para áreas de favelas são encorajadores, já que se mostraram precisos e pouco ambíguos no processo de classificação, o que permitiria a sua utilização por gestores urbanos.

Palavras-chave: favelas, classificação orientada a objetos, *eCognition*, imagens IKONOS II.

Abstract - CLASSIFICATION OF SLUM AREAS USING IKONOS IMAGES: VIABILITY OF USING THE OBJECT-BASED CLASSIFICATION APPROACH. The growth of large cities is usually accelerated and disorganized, which causes social, economical and infrastructural conflicts and frequently, occupation in illegal areas. For a better administration of these areas, the public manager needs information about their location. This information can be obtained through land utilization and land cover maps, where orbital images of remote sensing are used as one of the most traditional sources of data. In this context, the present work tested the applicability of the object-based classification to categorize two slum areas, taking into account the structure of the streets, size of the huts, distance between the houses, among other parameters. These area combinations of physical aspects were analyzed using the image IKONOS II and the software *eCognition*. Slum areas tend to be, to the contrary of the planned areas, disarranged, with narrow streets, small houses built with a variety of materials and without definition of blocks. The results of land cover classification for slum areas are encouraging because they are accurate and little ambiguous in the classification process. Thus, it would allow its utilization by urban managers.

Keywords: slums, object-based classification, *eCognition*, IKONOS II images.

1. Introdução

Nas últimas décadas, as cidades sofreram um processo de urbanização diferenciado. O crescimento das grandes e médias cidades ocorreu de forma acelerada e desorganizada, ocasionando conflitos de ordem social, econômica e de infra-estrutura. Esse crescimento desordenado é um problema que atinge a todos os planejadores, já que os órgãos públicos responsáveis pelo planejamento urbano não conseguem controlar o avanço das ocupações irregulares, surgindo, assim, lotea-

mentos clandestinos e irregulares, como as favelas, todos os dias.

Para um melhor gerenciamento dessas áreas ilegais, o poder público necessita de informações que descrevam quais são, onde estão e o que poderá ser feito para a regularização da situação em espaços de tempos curtos. Porém, esses materiais ainda demoram a ser atualizados pela dificuldade de levantamento de áreas de favelas. Uma alternativa para subsidiar os gestores, com vista a minimizar o problema, é o uso de imagens de satélite para produzir mapas de uso e cobertura da terra.

A utilização de imagens orbitais, empregadas a áreas urbanas, tem aumentado, à medida que suas potencialidades têm sido demonstradas e confirmadas em diferentes aplicações, tais como mapeamento do espaço intra-urbano, controle de ocupações irregulares, detecção de ocupações informais, entre outras. Atualmente, devido ao avanço tecnológico tanto de sensores orbitais quanto de programas que se assemelham ao que realmente existe no local, mesmo em caso de favelas (casebres de vários materiais sem arruamentos definidos) podem ser desenvolvidos.

Nesse contexto, o presente trabalho testou a aplicabilidade da classificação orientada a objeto para classificar áreas faveladas, levando em consideração a estrutura dos arruamentos, tamanho dos barracos, distância entre as casas, entre outros. A abordagem orientada por objetos assemelha-se à percepção humana na forma como a visão extrai a informação, que é baseada em objetos (Blaschke *et al.*, 2000).

Primeiro, a percepção de áreas homogêneas, ou objetos, é posteriormente caracterizada por uma rede complexa de experiência e conhecimento. De maneira semelhante, a análise orientada por objetos é executada em duas etapas: a de segmentação e a de classificação. Na etapa de segmentação, são criados os objetos que servem de base para uma classificação.

A partir do uso de imagem IKONOS II e do programa *eCognition*, foi analisado o arranjo da área, considerando como conceito que áreas faveladas, contrariamente às áreas planejadas, são

desarranjadas, com ruas estreitas, casas pequenas construídas com os mais variados materiais e sem definição de quadras.

2. Área de estudo

Foram selecionadas duas áreas na cidade de São José dos Campos - SP - Brasil. Esta cidade foi escolhida como área de estudo por apresentar uma ocupação urbana acelerada (cerca de 90% da população é urbana) e por possuir uma grande quantidade de favelas em áreas de ocupação irregulares. Além desses fatores, está localizada no Médio Vale do Paraíba do Sul, entre as metrópoles do Rio de Janeiro e São Paulo, e está circundada por várias cidades menores como Jacareí e Guaratinguetá, entre outras. Seu território abrange uma área de 1.099,60 Km², compreendido entre as latitudes 23°18'S e 22°49'S e longitudes 46°06'O e 45°40'O (PMSJC, 1994).

A primeira área que serviu como base para a classificação está localizada a sudeste da cidade de São José dos Campos e é denominada favela Chácara Reunidas (ocupa 13% da área total de favelas). A segunda, que foi a área usada para verificar a eficiência do método adotado, fica ao norte da cidade e é denominada favela Nova Esperança (popularmente conhecida por Banhado). Estas áreas de interesse estão apresentadas na figura 1A (Favela Chácara Reunidas) e 1B (Favela Nova Esperança) indicadas na imagem por polígono tracejado.




Figura 1. (A) Favela Chácara Reunidas; (B) Favela Nova Esperança.

3. Métodos

A imagem IKONOS II foi escolhida por estar disponível para a área e por ser de alta resolução. Ao se estudar a classificação da cobertura da terra em áreas de favela, deve-se ter em mente que o espaço intra-urbano, onde estão dispostas as favelas, é constituído por alvos heterogêneos e, ao mesmo tempo, fortemente influenciado em suas refletâncias pelos alvos vizinhos, ou seja, esses alvos têm respostas espectrais muito próximas, promovendo confusão durante o processo de classificação e dificultando a separação de alvos.

Já o programa para realização da classificação adotado foi o *eCognition*, por realizar uma abordagem orientada a objetos que as classificações mais usuais, como a Maxver, não possuem. Seu processo de segmentação trabalha em vários níveis, o que permite uma segmentação multirresolução, portanto com uma melhor separação dos alvos.

Para a classificação, tomou-se a área de interesse para realizar o primeiro passo da classificação - a segmentação por multirresolução. Na sequência, foi elaborada uma rede hierárquica com base nas relações existentes entre os objetos presentes na imagem, visando facilitar o processo de classificação orientada a objetos de cobertura da terra para áreas de favelas.

3.1. Segmentação

Durante a segmentação multirresolução, foram respondidas questões relativas ao tipo de estratégia de segmentação realizada e a quantidade de níveis que se pretendia segmentar a imagem. Posteriormente, foram realizados testes buscando-se obter os fatores de escala, de forma e de compacidade de acordo com os objetos que se desejava separar na imagem. Para realizar este processo de segmentação no programa *eCognition*, foi necessário fornecer valores a três fatores: escala, cor/forma e suavidade/compacidade (Definiens, 2004). O parâmetro de escala é a medida para a variação máxima em heterogeneidade, que pode ocorrer na fusão de dois objetos. Internamente, esse valor é elevado ao quadrado e serve como limiar para o término do algoritmo.

O critério geral de heterogeneidade é composto pelos parâmetros, denominados heterogeneidade de cor e de forma.

A cor constitui-se de uma soma ponderada dos desvios padrões de cada banda para uma

determinada região. O peso de cada banda é estabelecido pelo usuário e varia entre 0 e 1 (Definiens, 2004). Segundo Hofmann (2001), os valores de níveis de cinza das bandas multiespectrais possuem uma correlação significativa e, ao utilizar o mesmo peso para cada banda, é encontrado um resultado bastante razoável.

A forma é um atributo que leva em consideração os critérios de compacidade e suavidade, com intervalo variando de 0 a 1.

Compacidade é a razão entre o perímetro de um objeto pela raiz quadrada do número de pixels, enquanto a suavidade é a razão entre o perímetro do objeto e o perímetro do *bounding box*, ou seja, do retângulo envolvente às bordas da imagem com menor comprimento possível.

Com base nas classes de interesse, teve início o processo de segmentação para encontrar os melhores valores dos parâmetros exigidos nesse processo, bem como para extrair os objetos de interesse na imagem. Ao final, foram estabelecidos três níveis de segmentação.

No nível mais fino, tentou-se separar o máximo de feições da imagem, com grande quantidade de detalhes. Após vários testes, foi estabelecido o melhor fator de escala para este nível, com uma amostragem significativa de 10 objetos na imagem.

Já no nível médio, tentou-se separar a área da vegetação do resto da imagem e, no nível mais grosseiro, as quadras e não-quadras. Para encontrar o fator de escala no nível médio, foi utilizada a teoria dos super-objetos (objetos agrupados formando objetos agrupados formando super-objetos ou regiões) dos 10 objetos da amostragem para o nível fino. No nível mais grosseiro, utilizou-se um fator de escala que fosse pequeno o suficiente para separar apenas o que é favela do que não é. Essa segmentação teve por objetivo separar as áreas de favela do restante, até chegar ao nível onde os objetos extraídos na imagem eram as classes de cobertura de terra para favelas. No quadro 1, são apresentados os valores utilizados em cada nível e estão identificados, além dos valores de fator de escala, os pesos adotados para cada parâmetro de segmentação, além de cada *layer* temático contendo quadras e ruas, importado do programa *Envi*. Na segmentação do nível médio, foi utilizada somente a imagem NDVI (Índice de Vegetação Normalizado), porque o objetivo desse nível era separar vegetação do que não era vegetação.

Após a segmentação, foi realizada a avaliação visual das imagens segmentadas, para que pudesse

ser analisado o desempenho obtido, de acordo com o que se desejava extrair e o que foi realmente extraído. Nessa avaliação, buscou-se ainda feições

do terreno que ficaram divididas em um ou mais objetos, a fim de fundi-las e melhorar, com isso, o resultado da segmentação.

Quadro 1. Parâmetros da Segmentação.

NÍVEL	CLASSE	ESCALA	COR	FORMA	COMPACIDADE	SUAVIDADE
Fino	Tipos de Coberturas	15	0,7	0,3	0,5	0,5
Médio	Vegetação e Não-Vegetação (Quadras, sombras, solo exposto)	50	0,7	0,3	0,5	0,5
Grossoiro	Quadras e Áreas Não-Planejadas	1000	0,1	0,9	0,5	0,5

3.2. Formulação da rede hierárquica

A rede hierárquica foi gerada a partir das chaves de interpretação. Bishr (1997) salienta que o contexto é expresso através de definições semânticas dos objetos e de suas estruturas descritivas, ou seja, por meio da relação de significância de um objeto em relação ao meio que está inserido, desenvolveram-se estruturas para agrupar da melhor maneira possível esses objetos, de tal forma que seja possível reconhecê-los mais facilmente.

Em seguida, as classes foram distribuídas nos níveis hierárquicos, de acordo com a escala de segmentação em que se encontravam por meio de sua semântica. Com isso, obteve-se uma segmentação que forneceu informações sobre a identidade de cada objeto no nível hierárquico. Esse método gerou uma rede semântica onde as relações entre os objetos puderam ser expressas através de relações de atributos do objeto. Os agrupamentos de cada objeto geraram uma rede hierárquica em que as relações semânticas entre eles se dão de forma que o objeto seja parte de uma classe, tipo de uma classe ou é da classe X; por exemplo, telha faz parte da classe cerâmica (Antunes, 2003).

A rede foi aplicada em duas áreas, uma para analisar a viabilidade de uso da rede e outra para confirmar o grau de eficiência obtido e o seu uso em outras áreas com características semelhantes. Isso, resumidamente, quer dizer que, se a rede funcionar para duas áreas diferentes de favelas, poderá ser aplicada em outras áreas de favelas com características semelhantes.

3.3. Classificação

A metodologia orientada a objeto permite que o usuário interaja com o processo de classifica-

ção, baseado em informações espectrais, de textura, de forma e de topologia entre os segmentos. Nessa classificação, as classes escolhidas são amostras de regiões formadas pela segmentação e não mais por pixel a pixel. O objetivo é tornar o processo de mapeamento ou reconhecimento de características da superfície terrestre menos subjetivo e com maior potencial de repetição em situações subseqüentes (Novo, 1989), idéia proposta pelo presente trabalho.

Essa técnica permite extrair atributos, quantificando-os pelos níveis radiométricos, com a finalidade de agrupá-los e classificá-los por suas características em classes de análise. Nesse sentido, o classificador orienta a busca na definição de classes de cobertura a partir da segmentação feita anteriormente e das classes previamente definidas por meio de seus respectivos atributos.

Durante o processo de classificação, cada objeto é indicado a pertencer a uma determinada classe e conecta-se à hierarquia daquela classe. O resultado da classificação é uma rede de imagem classificada determinada pelos atributos, relações de uma classe com a outra e relações da classe na hierarquia modeladas por funções *Fuzzy*. Segundo Encarnação *et al* (2005), a função de pertinência *Fuzzy* de um objeto a uma determinada classe é dada por: i) escolha do operador lógico, ii) da função, e iii) descritores dos objetos.

O operador *Fuzzy* define a base de regras da rede hierárquica para avaliar os graus de pertinência de cada segmento às classes estabelecidas. (Mansor *et al.*, 2002). Para inserir esse conhecimento dos objetos, dois fatores foram levados em consideração neste processo: quais descritores serão utilizados para diferenciar cada classe e qual o tipo de regra de decisão será adotada para cada classe.

São muitos os tipos de descritores que o *eCognition* disponibiliza. O programa apresenta vários recursos que auxiliam na construção das funções para separar cada classe, baseados em descritores do objeto, de relacionamento das classes, relacionamento global (relação do objeto com o todo, similaridade do objeto na cena, etc.) e operadores lógicos (média, adição, entre outros).

De acordo com Definiens (2004), os descritores do objeto se subdividem em vários outros, tais como: espectrais, textura, forma, hierarquia e temático. Os descritores espectrais fornecem informações dos valores espectrais das bandas e do relacionamento com atributos espectrais de vizinhança. Os descritores de forma se subdividem em valores de área, perímetro, largura, grau de simetria (quanto um objeto é semelhante na forma em relação a outro), densidade e direção principal. Os de textura são baseados na variação espacial dos valores espectrais dos detalhes contidos no objeto. Os des-

critores de hierarquia trazem informação de posicionamento do objeto no nível hierárquico, como por exemplo: o nível ao qual o objeto está associado, a quantidade de vizinhos e a quantidade de níveis acima e abaixo do nível do objeto. Os temáticos são informações adicionais que se importa para auxiliar a classificação como tipos de solo.

Os descritores de relacionamento são utilizados para unir funções a partir da associação com outros objetos da rede. Os relacionamentos globais recorrem a parâmetros estatísticos para a cena ou para uma classe.

A formulação de regras *Fuzzy*, apoiadas nesses diferentes descritores dos objetos, permite a realização da semântica dos objetos ou regiões e, conseqüentemente, possibilita uma classificação interativa e próxima à realidade (Quint, 1997). Essa classificação pode ser avaliada no quadro 2, observando as funções e descritores usados para elaborar o processo de classificação ora proposto.

Quadro 2. Rede hierárquica produzida para classificação de favelas.

Classes		Nível 3 - Super-objetos		Função	Descritores
Área de Favelas - N3				∧	Média da Banda 2
Área sem interesse - N3					Negação da área de Favela
		Nível 2 - Super-objetos			
Área de Favelas N2 (Herança da área de favelas - N3)	Sombra			∧	Níveis de brilho
	Vegetação			∧	Média da imagem NDVI + Negação de sombra
	Solo exposto + Área construída				Negação de sombra + Negação de Vegetação
Área sem interesse - N2 (Herança da área sem interesse - N3)					
Área sem interesse - N1 (Herança da área sem interesse - N2)					
Sombra - N1 (Herança da sombra - N2)					
Vegetação - N1 (Herança da vegetação - N2)	Arbórea			□	Média da imagem NDVI
	Rasteira				Negação de arbórea
		Nível 1 - Sub-objetos			
Cobertura - N1 (Herança de solo exposto + Área construída - N2)	Vermelho (Descritor: Média da imagem NDVI)	Vermelho escuro (Descritor: Média da imagem NDVI)	Cobertura Cerâmica escura	□	Não existe
			Solo exposto escuro	∧	Classificado como vermelho escuro
		Vermelho claro (Negação de vermelho escuro)	Cobertura Cerâmica clara		Não existe
			Solo exposto claro	∧	Classificado como vermelho claro
	Não Vermelho (Descritor: negação de Vermelho)	Cobertura Metálica		□	Níveis de brilho
		Acinzentados (Descritor: Negação de cobertura metálica)	Cob. Concreto/Amianto escuro	□	Níveis de brilho
			Cob. Concreto/Amianto claro		Negação de Cob. Concreto/Amianto Escuro

4. Resultados

Na figura 2 pode-se constatar o processo pelo qual foi aplicada a metodologia com a estruturação das imagens durante o processo de segmentação e classificação. Esse foi o modelo da primeira imagem (Favela Chácara Reunidas), porém mesma estruturação foi aplicada para a segunda área.

No nível grosseiro, foram extraídas grandes regiões, que permitiram a distinção de áreas de favelas do restante da cena. No nível médio, o intuito foi fazer uma segmentação que separasse super-objetos na cena, a fim de classificar vegetação de não-vegetação. A área que não continha vegetação foi dividida em quadras, arruamento e sombra. No nível fino, a segmentação foi feita com base nas fei-

ções que se pretendia que fossem separadas para que o objetivo de classificar os tipos de cobertura da terra para áreas de favela fosse atingido. Os ní-

veis de classificação seguiram o processo inverso ao da segmentação.




Figura 2. Estrutura da segmentação multirresolução e classificação para áreas de favelas

O resultado da classificação, para a favela Chácara Reunidas, pode ser visualizado na figura 3.

Pela análise da figura 3, é possível observar visualmente que o resultado da classificação foi satisfatório, discriminando bem as classes de interesse na imagem com erros aceitáveis no processo de classificação. Quando esses erros foram percebidos visualmente, ainda durante o processo, eles foram corrigidos com a ferramenta de classificação manual. Nas classes de coberturas cerâmicas não houve classificação, por não ter ocorrência nesta favela.

A acurácia obtida foi de 79% e pode, de acordo com a literatura, ser considerada satisfatória. O índice *Kappa* foi considerado muito bom para esta classificação, ficando no intervalo entre 60 e 80%, conforme preconiza a literatura principalmente Landis e Koch (1977).

Utilizou-se o índice de ambiguidade para analisar o desempenho das funções de pertinência utilizadas no processo de classificação. O Índice de ambiguidade (I_a) proposto por Antunes (2003) é a razão da diferença dos dois maiores graus de pertinência pelo maior grau de pertinência, apresenta-

do na equação 1. Os Valores de I_a variam de 0 a 1. O valor 1 indica que não há incerteza na associação de um objeto a uma determinada classe e o valor zero indica total incerteza, como pode ser visto no quadro 3.

A acurácia obtida foi de 79% e pode, de acordo com a literatura, ser considerada satisfatória. O índice *Kappa* foi considerado muito bom para esta classificação, ficando no intervalo entre 60 e 80%, conforme preconiza a literatura principalmente Landis e Koch (1977).

Utilizou-se o índice de ambiguidade para analisar o desempenho das funções de pertinência utilizadas no processo de classificação. O Índice de ambiguidade (I_a) proposto por Antunes (2003) é a razão da diferença dos dois maiores graus de pertinência pelo maior grau de pertinência, apresentado na equação 1. Os Valores de I_a variam de 0 a 1. O valor 1 indica que não há incerteza na associação de um objeto a uma determinada classe e o valor zero indica total incerteza, como pode ser visto no quadro 3.

$$I_a = (b_{c1} - b_{c2}) / b_{c1} \quad (1)$$

onde:

b_{c1} - maior grau de pertinência para uma classe c_i qualquer;

b_{c2} - segundo maior grau de pertinência para uma classe c_i qualquer;

$c_i \neq c_j$

Os resultados obtidos por esta fórmula permitiram analisar o quanto é ambígua a classificação. A análise foi feita de acordo com uma escala de ambiguidades, também proposta por Antunes (2003), conforme indicado no quadro 3.




Figura 3. Classificação de Cobertura da Terra para a Favela Chácara Reunidas.

Quadro 3. Qualidade da Classificação: Índice de Ambigüidade ou instabilidade. Fonte: Antunes (2003).

Índice de ambigüidade Ou instabilidade	Qualidade
1. $I_a=0$	Inaceitável
2. $0,01=I_a=0,30$	Ambígua
3. $0,31=I_a=0,50$	Aceitável
4. $0,51=I_a=0,80$	Boa
5. $0,81=I_a=1$	Muito boa

No quadro 4 estão apresentados os valores de *Kappa* para cada classe e os resultados dos índices de ambigüidade.

Com base no quadro 4, depreende-se que esses índices de ambigüidades aferiram o quão dúbia ou instável é a associação de determinado objeto à determinada classe, durante o processo de classificação. Porém, essa incerteza demonstra apenas a possibilidade de ter sido cometido um erro ao optar pelo maior grau de pertinência como

critério de associação.

Ao analisar o processo de classificação quanto ao índice de ambigüidade - que analisa se a função *Fuzzy* cumpriu seu papel no processo de classificação sem confundir os objetos no resultado final - considera-se no geral, um desempenho aceitável das funções de pertinência *Fuzzy*, utilizadas para realizar o processo de classificação. Das oito classes ocorridas na área de interesse, apenas uma obteve um índice para classificação ambígua - a classe sombra (no quadro 4 em negrito).

Mas analisando de uma maneira geral isso pode ter ocorrido pela segmentação da sombra e pela interferência dos alvos que geraram as sombras. Nessa área, as sombras foram geradas principalmente por árvores altas, e as mesmas têm influência da vegetação rasteira. Porém, a peculiaridade das respostas espectrais da sombra fez com que, no processo de associação, seu primeiro grau de pertinência foi de valor máximo (1), o que comprova que foi um bom processo de classificação, com bons resultados, próximos aos resultados obtidos pelo índice de concordância das classes.

Quadro 4. Valores de *kappa* e de ambiguidade de cada classe de cobertura.

CLASSE	IA	AMBIGUIDADE	Kappa
Cobertura Cerâmica Escura	-----	-----	-----
Cobertura Cerâmica Clara	-----	-----	-----
Cobertura Concreto/Amianto Escuro	0,503	Boa	0,802
Cobertura Concreto/Amianto Claro	0,599	Boa	0,556
Cobertura Metálica	0,387	Aceitável	0,736
Sombra	0,246	Ambígua	0,535
Solo Exposto Escuro	0,535	Boa	0,524
Solo Exposto Claro	0,326	Aceitável	0,736
Vegetação Arbórea	0,525	Boa	0,945
Vegetação Rasteira	0,853	Muito boa	1

Para validação, o método foi aplicado na segunda área de favela selecionada. Foram apenas modificados alguns dos intervalos das funções, já que se desejava a aplicação de um método que pudesse ser utilizado em outras áreas de mesma característica com as menores mudanças possí-

veis, seja na rede hierárquica, nos atributos ou nas funções *Fuzzy* formadas por eles.

O resultado de classificação da Favela Nova Esperança obtido por meio dessa estrutura pode ser visto na figura 4.




Figura 4. Classificação de Cobertura da Terra para a Favela Nova Esperança.

Essa área era um pouco diferente da primeira (alvos constituintes diferentes), mas mesmo assim apresentou um resultado satisfatório na classificação. Desta maneira, o uso deste método é válido para outras áreas, desde que sejam incluídas nele classes que estejam presentes em outras localidades, aqui inexistentes, como cobertura cerâmica, por exemplo.

Tanto o coeficiente de concordância *Kappa* como a acurácia para essa classificação tiveram bons resultados. A acurácia ficou em torno de 65% e o coeficiente *Kappa* obteve um valor próximo de 60%, valor esse que, segundo Landis e Koch (1977), está dentro do intervalo de 40-60 que é considerado bom.

Para avaliar a estabilidade do processo de classificação, também foram calculadas as ambiguidades existentes no mesmo, por meio do índice de ambiguidade.

O quadro 5 apresenta os graus de pertinên-

cia para cada classe, bem como, categoriza a instabilidade presente no processo de classificação e compara esses resultados com o índice de concordância *Kappa* para cada classe.

Figura 3. Classificação de Cobertura da Terra para a Favela Chácara Reunidas.

CLASSE	I _A	AMBIGUIDADE	<i>Kappa</i>
Cobertura Cerâmica Escura	-----	-----	-----
Cobertura Cerâmica Clara	-----	-----	-----
Cobertura Concreto/Amianto Escuro	0,241	Ambígua	0,574
Cobertura Concreto/Amianto Claro	0,675	Boa	1
Cobertura Metálica	0,430	Aceitável	0,401
Sombra	0,241	Ambígua	1
Solo Exposto Escuro	0,601	Boa	0,708
Solo Exposto Claro	0,500	Aceitável	0,417
Vegetação Arbórea	0,567	Boa	0,431
Vegetação Rasteira	0,671	Boa	1

Pela análise do quadro 5 verifica-se que, provavelmente devido ao fato das duas áreas serem geograficamente diferentes, houve mais confusão no processo de classificação do segundo experimento, já que o método foi elaborado para o experimento 1. Isso fica mais claro quando se faz a análise de que, dentre as oito classes obtidas pelo processo de classificação, duas são ambíguas (no quadro 5 em negrito), enquanto as demais classes foram consideradas de qualidade boa ou aceitável. Nenhuma das funções de pertinência adotadas no processo obteve êxito pleno de associar o objeto à classe, porém, dentro da escala de avaliação da ambiguidade, é possível considerar o resultado da classificação como satisfatório, pois mesmo nas classes ambíguas, a classe concreto/amianto escuro tem pertinência 1, ou seja, dificilmente ela foi associada erroneamente. Isso remete a apenas uma classe no processo que realmente implica incerteza na classificação, que é a classe sombra. Assim sendo, esse resultado não prejudica a análise, podendo-se considerar que o método foi satisfatório para separar e classificar os alvos com um bom grau de confiabilidade.

Dessa maneira, a avaliação por meio do índice de ambiguidade e do grau de concordância, entre o que foi classificado e o que realmente existia *in loco*, trouxe a comprovação da aplicabilidade do método de classificação orientada a objeto disponível no programa *eCognition* para classificar coberturas de favelas. Esse tipo de classificação mostrou-se eficiente para análises em áreas heterogêneas e com alvos a serem extraídos de tamanho significantemente pequeno, com desempenho satisfatório.

5. Conclusões

Este trabalho propôs uma metodologia pouco explorada, que consistiu na classificação de cobertura da terra para áreas de favelas em imagens de alta resolução, ou seja, a classificação de áreas bastante heterogêneas, com alvos de tamanhos variados, sem uma organização territorial, em contraponto ao que acontece em áreas urbanas planejadas.

O método proposto possibilitou diferenciar feições que apenas pela resposta espectral não seria possíveis, devido à grande heterogeneidade encontrada em áreas de favelas. Outros classificadores já dispõem de ferramentas que facilitam a classificação, mas a utilização dos descritores, disponíveis no *eCognition*, na formação das funções de pertinência *Fuzzy*, ajudaram positivamente no processo de atribuir objetos a classes mais corretas. Um exemplo disso foi a diferenciação de alvos que, espectral ou texturalmente, ficaria prejudicada, como, por exemplo, para solo exposto e telhados cerâmicos.

O intuito de testar a aplicabilidade do método de classificação de imagens orientadas a objeto foi importante no trabalho. Os resultados foram satisfatórios quando comparados a processamentos convencionais, como o método de classificação por máxima verossimilhança, citados em outros trabalhos.

Com a realização deste trabalho, foi compreendido que a utilização do conceito de objeto é crucial em classificações de imagens quando se deseja um nível de detalhamento próximo às feições do mundo real, pois a informação semântica necessária para interpretação de uma imagem não está presente no alvo e sim nos objetos da imagem e nas relações entre eles. Este é um diferencial do *eCognition*, pois fazendo testes de segmentação, hierarquias e funções *Fuzzy*, obtém-se um resultado numa imagem com uma resolução espacial próxima à do objeto. Assim, quanto maior for a resolução espacial da imagem, melhores serão os resultados obtidos, o que permitirá que a classificação obtida tenha feições mais próximas aos objetos reais, possibilitando, até medidas com grande precisão e acurácia.

É possível concluir que esse método pode ser utilizado para áreas heterogêneas e de difícil separabilidade, como é o caso das favelas. Com o desenvolvimento de outros sensores que apresentem resoluções espaciais melhores, a tendência é conseguir resultados mais eficazes que os aqui apresentados e que poderão ser usados para atualização de plantas cadastrais. Porém, para verificação de onde e como está distribuída a favela na cidade, o trabalho pode ser usado sem problemas por gestores públicos como uma ferramenta para tomada de decisões para um melhor planejamento urbano.

A metodologia desenvolvida não é adequada para que sejam realizadas medidas nos resultados obtidos, pois as áreas delimitadas num processo de classificação podem apenas ser estimadas e não oferecem absoluta precisão.

Referências

- Antunes, A.F.B. 2003. *Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial*, PR. Curitiba, 146p. Tese de Doutorado, Ciências Geodésicas, Universidade Federal do Paraná.
- Bishr, Y. 1997. Semantic aspects of interoperable GIS. *ITC publication*, 56.
- Blaschke, T., Lang, S., Lorup, E., Strobl, J. & Zeil, P. 2000. *Environmental Information for Planning, Politics and the Public*. Marburg, Metropolis-Verlag, 555- 570p.
- Definiens, *eCognition*, User's Guide 3.0. Disponível em: www.definiensimaging.com/documents/index.htm. Acesso em: agosto de 2004.
- Encarnação, S.A., Tenedório, J.A. & Rocha, J. 2005. *Segmentação multiresolução e classificação orientada a objeto de imagens SPOT*. Disponível em: http://www.igeo.pt/igeo/portugueses/servicos/cdi/biblioteca/publicacoesigp_files/esig_2004/p068 >. Acesso em: 23 de junho de 2005.
- Landis, J.R. & Koch, G.G. 1977. The measurement of observer agreement for categorical data. *Biometrics*, 33(1): 159-174.
- Mansor, S., Hong, W.T. & Shariff, A.R.M. 2002. Object oriented classification for land cover mapping. In: ASIAN CONFERENCE ON REMOTE SENSING, 23, Kathmandu, 25-29 de novembro de 2002. Kathmandu, Nepal. Disponível em: www.gisdevelopment.net/application/environment/overview/envo0010pf.htm > Acesso em: 23 de março de 2004.
- Novo, E.M.L. 1989. *Sensoriamento Remoto: princípios e aplicações*. São Paulo, Edgard Blücher.
- Prefeitura Municipal de São José dos Campos (PMSJC). 1994. *Plano Diretor de Desenvolvimento Integrado*. São José dos Campos. 308p.
- Quint, F. 1997. *Aerial image understanding using digital map-based semantic model*. Institute of Photogrammetry and Remote Sensing. University of Karlsruhe. Disponível em: <http://digbib.ubka.uni-karlsruhe.de/volltexte/documents/1211> > Acesso em: 23 de junho de 2005.