unesp UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Ciências e Tecnologia
Programa de Pós-Graduação em Ciências Cartográficas

ELIANE APARECIDA ESTEVAM

CLASSIFICAÇÃO DE ÁREAS DE FAVELAS A PARTIR DE IMAGENS IKONOS: VIABILIDADE DE USO DE UMA ABORDAGEM ORIENTADA A OBJETOS

PRESIDENTE PRUDENTE
2006

unesp UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Ciências e Tecnologia
Programa de Pós-Graduação em Ciências Cartográficas

ELIANE APARECIDA ESTEVAM

CLASSIFICAÇÃO DE ÁREAS DE FAVELAS A PARTIR DE IMAGENS IKONOS: VIABILIDADE DE USO DE UMA ABORDAGEM ORIENTADA A OBJETOS

Relatório de Dissertação de Mestrado apresentado ao Programa de Pós-Graduação em Ciências cartográficas daFCT-UNESP – Campus de Presidente Prudente.

ERIVALDO ANTONIO DA SILVA
Orientador

PRESIDENTE PRUDENTE
2006

Ficha cartográfica elaborada pelo Serviço Técnico de Biblioteca e Documentação
UNESP – FCT – Campus de Presidente Prudente

E84c Estevam, Eliane Aparecida.
Classificação de áreas de favelas a partir de imagens Ikonos : viabilidade de uso de uma abordagem orientada a objetos / Eliane Aparecida Estevam. – Presidente Prudente : [s.n.], 2006
127 f.

Dissertação (mestrado) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia
Orientador: Erivaldo Antonio da Silva

1. Cartografia. 2. Alta resolução. 3. Favela. 4. Classificação orientada a objetos I. Silva, Erivaldo Antonio da. II. Estevam, Eliane Aparecida. III. Título. CDD (18.ed.) 623.71

UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Campus de Presidente Prudente

Comissão Examinadora

Prof. Dr. Erivaldo Antonio da Silva (Orientador)

Profa. Dra. Maria de Lourdes Bueno Trindade Galo

Prof. Dr. Luiz Felipe Guanaes Rego (PUC-RJ)

Eliane Aparecida Estevam

Presidente Prudente (SP), 07 de abril de 2006

Resultado: APROVADO

Faculdade de Ciências e Tecnologia
Seção de Pós-Graduação
Rua Roberto Simonsen, 305 CEP 19060-900 Presidente Prudente SP
Tel 18 229-5352 fax 18 223-4519 posgrad@prudente.unesp.br

A Deus eu ofereço

Ao meu amado marido Rodrigo que ajudou tornar esse sonho realidade eu dedico

AGRADECIMENTOS

Agradeço a Deus por ter me dado força, conhecimento e coragem para realizar esse trabalho;

Agradeço a todas as pessoas e instituições que ajudaram de forma direta e indireta a tornar esse sonho numa realidade, em particular a:

À Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES, pela bolsa concedida;

Ao Instituto Nacional de Pesquisas Espaciais – INPE, pela oportunidade de estudos e utilização de suas instalações.

Ao meu orientador Dr. Erivaldo Antonio da Silva, pela confiança depositada.

À Dra. Maria de Lourdes Bueno Trindade Galo, pelas sugestões ao meu trabalho.

À empresa Intersat, pelo fornecimento das imagens utilizadas neste trabalho.

Aos meus companheiros de mestrado, pelas horas que dividimos estudando para as provas, discutindo sobre nossos trabalhos e até mesmo dando força nas horas que eu achava que não ia conseguir concluir este trabalho. Muito obrigada, Renata, Edgar, Dalila, Rosatti e Lauri.

Aos alunos da pós-graduação que me orientaram nas dúvidas, Adriana, Ednéia, Giovane, Eniuce, Zanin, Mário, Vasco, Aninha e Cris.

A todos os professores do Programa de Pós-Graduação em Ciências Cartográficas, que tiveram paciência para explicar os tópicos ou exercícios não entendidos.

À minha família, em especial meu marido, meus pais, e meus irmãos, que confiou em mim e sempre me apoiaram.

A todos que direta ou indiretamente me ajudaram nessa pesquisa.

“Sábio é aquele que conhece os limites da própria ignorância”.

(Sócrates)

RESUMO

Com o avanço da tecnologia de sensoriamento remoto e conseqüente maior disponibilidade de sistemas sensores, houve grande aumento nas opções de uso de produtos orbitais, principalmente com significativa melhoria nas resoluções. Com isto, a utilização desses produtos em áreas urbanas tem crescido demasiadamente à medida que suas potencialidades têm sido demonstradas e confirmadas em diferentes aplicações. Porém, um pré-requisito para extrair informações desses produtos é o conhecimento do comportamento espectral dos objetos da superfície a serem analisados e os fatores que interferem neste comportamento. Isso tornou-se possível devido aos sensores a bordo dos novos satélites estarem cada vez mais adequados a estudos urbanos, em função do aumento das resoluções espacial, espectral e radiométrica. A resolução espacial tende a se igualar a das fotos aéreas e com menor custo de produção. A quantidade de detalhes apresentados pela resolução de 1 metro ou sub-metro, possibilitará análise e mapeamento da terra a um nível ainda não realizado com imagens orbitais. Com a utilização de técnicas de sensoriamento remoto, foi proposto um método que teve por objetivo, analisar a aplicabilidade da classificação orientada a objetos para classificação de cobertura da áreas de favela em produtos de alta resolução. Para isso, foi utilizada uma cena do satélite IKONOS II da região urbana da cidade de São José dos Campos – SP, contendo a Favela Chácara Reunidas, para testar o método de classificação. A classificação foi realizada numa imagem fusão da banda pancromática com as multiespectrais para melhorar a visualização da imagem. Na seqüência foi realizada a etapa de classificação orientada ao objeto na cena obtida no processo de fusão. Esta etapa foi dividida em quatro partes: definição das classes de cobertura do solo com base em análise visual das imagens IKONOS; segmentação multi-resolução; criação da rede hierárquica e classificação de cobertura da terra para áreas de favela. A segmentação e a classificação da área teste foram efetuadas no *Software eCognition*. Em seguida o mesmo método foi testado para outra favela na mesma cidade a fim de validar o método. Os resultados obtidos mostraram-se encorajadores e estão apresentados e discutidos nesta dissertação. A grande contribuição deste trabalho é apresentar um método relativamente novo de classificação de imagens capaz de extrair alvos intra-urbanos em imagens de alta resolução, como neste caso áreas de favelas. Os resultados obtidos podem fornecer subsídios ao planejamento urbano, no momento de tomada de decisões.

Palavras-Chave: alta resolução, favela, classificação orientada a objeto.

ABSTRACT

With the technology progress of the remote sensoring and consequent greater sensor systems availability, there was a large increase in the significant improvement in the resolutions. In this way, the use of these products in urban areas has been increasing so much as while their potentialities has been demonstrated and confirmed to in the different applications. However, one pre-requirement to remove information from these products is the knowledge of the spectral behavior from the objects from the surface to be analysed and the agents which interfere in this behavior. This became possible because of the sensors aboard the new satellites that are each more appropriate to the urban studies, functioning as the spatial, spectral and radiometry increase. The spatial resolution extends to equate to the aerial pictures and with less production cost. The detail quantities presented by 1 meter or submeter resolution will become possible the analysis and the mapping of the earth to a level never reached in orbital images. With the remote sensoring techniques use, it was proposed one method that had the propose of analyzing the applicability of the guided classification to the objects for the classification of slum areas in light resolution products. For this, it was used one scenes of IKONOS II satellite of the city “São José dos Campos – SP” urban area, having the Slum Chácara Reunidas, to test the classification method. This was performed in a image merge from the panchromatic band with the multispectrum ones to improve the spatial resolution. In the sequence, it was performed the classification step guided to the scenes object obtained in the merge process. This step was divided in 4 parts: definition oh the covered earth classes based on visual analysis from IKONOS II images (visual); multiresolution segmentation; visual valuation of the segmentation with the propose of checking if were extracted the interested objects; and classification of the earth to the slum areas. The analysed area segmentation and classification were done in software eCognition. After, the same method was tested in other slum from the same city with the propose to validate the method. The achieved results were showed encouraged and are presented and discussed in this dissertation. The great contribution of this work is to present a method relatively new images classification capable to extract intra-urban goals in high resolution images , as in this case slums areas. The achieved results can provide subsidies for the urban project, in the moment of the having decisions.

Keywords: high resolution, slum, guided classification to the object.

LISTA DE FIGURAS

1- Assinaturas espectrais de tipos de cobertura urbana a partir do sensor AVIRIS. As melhores bandas de separação para cobertura urbana são destacadas por linhas verticais pretas e em cinza para o restante dos tipos de cobertura.....22

2- Ilustração dos conceitos de super e subobjeto, utilizando como exemplo a relação existente entre lotes e quadras.....38

3- Representação de informação da imagem por meio de uma rede hierárquica de objetos na imagem ligados por meio de arcos de acordo com a semântica dos objetos.....41

4- Representação da matriz de confusão.....48

5- Fluxograma dos procedimentos metodológicos desenvolvidos 56

6- Localização de São José dos Campos.....58

7- Localização das Favelas na cidade de São José dos Campos.....61

8- Área teste: Favela Chácara Reunidas e área de validação: Favela Nova Esperança.....63

9- Transformação IHS e fusão pelo método IHS de cores.....64

10- Histograma comparando as funções para solo exposto e telhado cerâmico no atributo média espectral na banda do vermelho.....70

11- Tipos de funções de pertinência fuzzy.....81

12- Formação da função fuzzy: um exemplo para a classe água e solo.....82

13- Rede hierárquica para o nível 3.....85

14- Rede hierárquica para o nível 2.....85

15- Rede hierárquica para o nível 1.....86

16- Rede Hierárquica para classificação de cobertura de favelas no eCognition.....87

17- Estrutura da segmentação multiresolutiva e classificação para áreas de favelas.....91

18- Segmentação e classificação para o nível 3.....92

19- Segmentação e classificação para o nível 2.....93

20- Segmentação e classificação para o nível 1.....93

21- Classificação de cobertura da terra para a Favela Chácara Reunidas.....94

22- Estrutura de segmentação e classificação para a favela Nova Esperança (Banhado).....101

23- Segmentação e classificação para o nível 3.....102

24- Segmentação e classificação para o nível 2.....102

25- Segmentação e classificação para o nível 1.....103

26- Classificação de cobertura da terra para a Favela Nova Esperança.....103

LISTA DE TABELAS

1- Características do sensor Ikonos II.....19

2- Qualidade da classificação segundo intervalos do coeficiente de Concordância Kappa.....52

3- Qualidade da Classificação: Índice de ambigüidade ou instabilidade.....54

4- Resultado de interpretação nos domínios da imagem e dos segmentos.....68

5- Parâmetros de segmentação.....75

6- Tipos de atributos disponíveis no programa eCognition.....79

7- Relação da rede hierárquica entre objetos e descritores.....89

8- Matriz de confusão e coeficiente Kappa para a Favela Chácara Reunidas.....95

9- Grau de ambigüidade comparada com o índice de concordância Kappa por classe para a classificação da favela Chácara Reunidas.....98

10- Matriz de confusão e coeficiente Kappa para a Favela Nova Esperança.....105

11- Índice de ambigüidade e Kappa para cada classe para a classificação da favela Nova Esperança.....108

SUMÁRIO

1. INTRODUÇÃO 11
2. FUNDAMENTAÇÃO TEÓRICA 14
2.1. URBANIZAÇÃO 14
2.1.1 Favela 15
2.2 SENSORIAMENTO REMOTO 16
2.2.1 Sensor IKONOS II 18
2.3 ALVOS INTRA-URBANOS 20
2.4 CLASSIFICAÇÃO DE IMAGENS 22
2.4.1 Interpretação da imagem 25
2.4.1.1 Elementos de interpretação 26
2.4.1.2 Chave de interpretação 28
2.4.2. Interpretação de imagens baseadas em conhecimento 29
2.5.1 Conceito de objeto 32
2.5.2 Abordagem orientada a objetos 32
2.5.3. SEGMENTAÇÃO 35
2.5.3.1 Segmentação orientada a regiões 36
2.5.3.2 Segmentação por multiresolução 37
2.5.4 Rede Hierárquica 40
2.5.5 Teoria dos conjuntos Fuzzy 43
2.5.6. Classificação orientada a objeto 45
2.6 AVALIAÇÃO DA CONFIABILIDADE DA CLASSIFICAÇÃO 46
2.6.1 Análise Kappa 51
2.6.2 Grau de instabilidade ou ambigüidade do processo de classificação 52
3.1 MATERIAIS UTILIZADOS 55
3.2 PROCEDIMENTOS METODOLÓGICOS 55
3.2.1 Trabalho de campo 56
3.2.2 Seleção das Imagens 57
3.2.3 Área de Estudo: São José dos Campos: breve histórico 57
3.2.4 Pré-processamento da imagem 64
3.2.5 Classificação da imagem 66
Definição das Classes 66
Segmentação 70
Formulação da rede hierárquica 76

Classificação 77
3.2 AVALIAÇÃO DA CLASSIFICAÇÃO 83
4. RESULTADOS 84
4.1 REDE HIERÁRQUICA 84
4.2 APRESENTAÇÃO E AVALIAÇÃO DOS RESULTADOS 90
4.2.1 Experimento 1: Área teste → Favela Chácara Reunidas 90
4.2.2 Experimento 2: Área de validação → Favela Nova Esperança (Banhado) ... 100
5. CONCLUSÕES 114
6. REFERÊNCIAS BIBLIOGRÁFICAS 117
7. BIBLIOGRAFIA 125

1. INTRODUÇÃO

O crescimento das grandes cidades geralmente ocorre de forma acelerada e desorganizada, ocasionando conflitos de ordem social, econômica e de infra-estrutura. Esse crescimento desordenado é um problema que atinge todos os planejadores, já que os órgãos públicos responsáveis pelo planejamento urbano não conseguem controlar o avanço das ocupações ilegais, surgindo assim, loteamentos clandestinos e irregulares, como favelas.

Favelas são um aglomerado de moradias alternativas constituídas de “casebres” instalados em locais impróprios ao uso e ocupação do solo, gerando um impacto local muito grande, tanto no cenário paisagístico, como no meio e na sociedade local. Essa área ilegal apresenta alta densidade demográfica e estrutura organizacional desordenada. Normalmente está localizada em áreas de risco ou ambientalmente irregulares, gerando uma paisagem diferenciada da “malha urbana normal”.

Para um melhor gerenciamento dessas áreas ilegais, o poder público necessita de informações que descrevam quais são e onde estão para poder decidir o que precisa ser feito para regularizar a situação de determinada área..

O reconhecimento de padrões de mudanças no uso e cobertura da terra pode fornecer elementos para responder algumas destas questões (Pinho, 2005). Por exemplo, ao identificar uma área de ocupação é possível planejar a alocação das famílias total ou parcialmente, ou tentar fornecer infra-estrutura e legalizar aquele local.

A imagem orbital ajuda nesse sentido, pois é uma das fontes mais tradicionais de dados para a confecção de mapas de uso e cobertura do solo. Com o aumento da resolução espacial dos produtos de sensoriamento remoto orbital se permiti a realização de mapeamentos, análises e monitoramento da área urbana, servindo de base para os profissionais responsáveis pelo planejamento urbano, pois estas informações auxiliam nas análises, previsão e controle de mudanças no espaço dinâmico.

Nesse sentido, a utilização de produtos de Sensoriamento Remoto aplicado a áreas urbanas tem aumentado a medida que suas potencialidades vêm sendo demonstradas e confirmadas para diferentes aplicações, tais como mapeamento do espaço intra-urbano, controle de ocupações irregulares, detecção de ocupações informais, entre outras.

Partindo do pressuposto da viabilidade em trabalhar com classificação orientada a objeto para áreas heterogêneas como favelas em imagens Ikonos foi empregado um método que se baseia numa avaliação de duas áreas faveladas em cenas do satélite IKONOS II. A idéia é localizar e analisar os componentes da área em função das feições contidas na imagem e classificar as coberturas da terra utilizando um sistema de classificação orientada a objeto. Com isso objetiva-se criar uma rede hierárquica para classificar áreas de favela e testá-la nas duas cenas selecionadas com a finalidade de verificar a aplicabilidade da mesma. Essa metodologia foi idealizada para favelas localizadas em cidades de médio e grande porte, e deve levar consideração a estrutura dos arruamentos, tamanho dos barracos, distância entre as casas, entre outros, já que favelas de cidades pequenas tem estruturação semelhante a bairros de classe baixa. Assim se considera áreas de favelas, nesta pesquisa, áreas desarranjadas, com ruas

estreitas, normalmente de solo exposto, casas pequenas construídas com os mais variados materiais e sem definição de quadras.

Assim a hipótese testada foi se este método pode ou não ser aplicado em áreas bastante heterogêneas produzindo resultados satisfatórios. Se comprovada a aplicabilidade do método, têm-se então informações que podem auxiliar na gestão dos espaços, planejando as cidades por meio de monitoramento da área e de informações bem próximas do real, rápidas e a um custo menor. Caso contrário, o método será considerado inviável para trabalhos com esse caráter.

Para isso essa dissertação foi dividida em 5 capítulos. O primeiro introduz o assunto a ser abordado. O segundo trata da fundamentação teórica que embasa o tema e está dividido em: problemas da falta de planejamento urbano que geram as favelas, breve abordagem sobre sensoriamento remoto e sistemas sensores, mas especificamente o sistema sensor Ikonos II, e por fim uma abordagem de classificação de imagem mais geral afunilando para a abordagem orientada a objeto.

No capitulo 3 é realizada uma breve descrição da área de estudo, bem como a localização das favelas e a seleção das duas cenas contendo áreas de favela. Neste capítulo também é detalhado o método desenvolvido a fim de alcançar o objetivo proposto. O capítulo 4 apresenta os resultados obtidos e uma breve discussão dos mesmos. O capítulo 5 contém as conclusões obtidas, as dificuldades encontradas e as sugestões para trabalhos futuros.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Urbanização

De acordo com os dados do IBGE (2005), em 60 anos triplicou o número de pessoas vivendo nas cidades do Brasil. Na década de 40, a população urbana brasileira era de 18,8 milhões de habitantes, passando em 2000 para cerca de 138 milhões.

As cidades cresceram em muito pouco tempo e essa grande expansão foi necessária para o assentamento residencial dessa população bem como de suas necessidades de trabalho, abastecimento, transporte, saúde, energia, água etc. Apesar desse crescimento urbano ter sido desigual, o território foi ocupado e foram construídas as condições para se viver nesse espaço. De algum modo, bem ou mal, improvisado ou definitivo, cerca de 138 milhões de habitantes do Brasil moram hoje nas cidades.

De acordo com Villaça (1986), cada vez mais, nossas cidades podem ser subdividas da seguinte forma: de um lado, a “cidade” dos que comandam e participam da sociedade, e de outro a “cidade” dos comandados, dos marginalizados, dos que estão de fora.

Maricato (2001) utiliza as expressões “cidade legal” e “cidade ilegal” para definir o mesmo fenômeno. De acordo com a autora, o número de imóveis ilegais na maior parte das cidades brasileiras é tão grande que a cidade legal caminha para ser espaço de poucos.

Vários foram os acontecimentos que fizeram com que as cidades crescessem: as exportações, o êxodo rural, a construção de ferrovias e a

implantação de indústrias nos seus mais variados gêneros (RODRIGUES, 1992). Muitos foram os imigrantes que vieram para o Brasil trabalhar nas fazendas e logo mudaram para as cidades. Essas foram crescendo e ganharam vida própria. O comércio desenvolveu e com ele as indústrias. Segundo Rodrigues (1992), em muitas cidades o crescimento ocorreu tão rapidamente que não acompanhou a urbanização necessária à boa qualidade de vida de seus habitantes.

Por esse motivo, nas cidades brasileiras, está cada vez mais difícil achar um lugar para morar por um preço acessível a todas as classes sociais. Com isso, o crescimento das grandes cidades geralmente ocorre de forma acelerada e desorganizada trazendo problemas de ordem social, econômica e de infra-estrutura, gerando as áreas denominadas por Maricato (2001), como área urbana “ilegal” ou também conhecidas por loteamentos clandestinos ou favelas.

2.1.1 Favela

Para Almeida e Abiko (2000) a definição mais apropriada para favela, nos dias atuais, seria “assentamento populacional espontâneo, localizado em área pública ou particular, de forma ilegal em relação à propriedade do solo e cujas edificações encontram-se em desacordo com as leis de uso e ocupação do solo, independentemente do número de unidades habitacionais existentes e das tipologias dos domicílios”. Segundo Taschner (1978), favela pode ser definida como um agrupamento de barracos, ou seja, de habitações de dimensões reduzidas, construídas com material inadequado (madeira velha, folhas de zinco, latões e até papelão), divididos irregularmente em terrenos ilegais, no que tange a títulos de

propriedade e desprovidos quase totalmente de equipamentos urbanos tais como água potável, esgoto, eletricidade e equipamentos sociais (saúde, lazer, escolas).

Esses assentamentos são realizados sem uma preparação prévia do terreno, sem infra-estrutura urbana e sem padronização de parcelamento e ocupação do solo urbano. Segundo Schuler e Araújo (2005), o que determina o traçado urbano caracterizado pela irregularidade são as limitações impostas pelo meio, as necessidades de acessibilidade às edificações e as limitações técnicas da comunidade.

2.2 Sensoriamento Remoto

Como a visão humana é naturalmente limitada, é necessário que o Homem como integrante da ciência, desenvolva "equipamentos artificiais" que possam também receber, quantificar e fornecer informações sobre os objetos estudados. O Sensoriamento Remoto, tecnologia que produz esses equipamentos, objetiva identificar alvos presentes no ambiente terrestre por meio do estudo entre a radiação eletromagnética e as substâncias componentes do planeta Terra em suas diversas manifestações. Novo (1989) define Sensoriamento Remoto como sendo "a utilização conjunta de modernos sensores, equipamentos para processamento de dados, equipamentos de transmissão de dados, aeronaves, espaçonaves etc., com o objetivo de estudar o ambiente terrestre através do registro e da análise das interações entre a radiação eletromagnética e as substâncias componentes do planeta Terra em suas mais diversas manifestações, sem o contato físico direto".

Com o desenvolvimento tecnológico, as bandas espectrais puderam ser ampliadas, sendo possível à sofisticação dos equipamentos (SILVA, 1995), sendo o principal o sensor. Segundo Novo (1989), sensor pode ser definido como qualquer equipamento capaz de transformar alguma forma de energia, convertê-la em sinal passível de ser registrado e apresentá-lo em forma adequada à extração de informações.

Os sensores atualmente disponíveis podem ser classificados por vários critérios (NOVO, 1989): quanto à fonte de energia, quanto à região do espectro em que operam e quanto ao produto final obtido da transformação sofrida pela radiação detectada.

Esses sistemas sensores podem ser classificados em função do produto final obtido pelo tipo de transformação sofrida e pela radiação detectada. Dessa forma, estão ordenados em: sistemas não-imageadores e sistemas imageadores.

Assim, os diferentes sistemas sensores são caracterizados por sua resolução, definida como a medida da habilidade que o sensor possui em discriminar entre respostas espectralmente semelhantes e espacialmente próximas. Além da resolução espacial, que mede a menor separação linear ou angular entre dois objetos da superfície terrestre, os sistemas de varredura dos satélites podem ser caracterizados pela sua resolução espectral, a qual se define como a medida da largura e o número de bandas espectrais, nas quais, o sensor opera; a resolução radiométrica, relacionada com a sensibilidade do sensor em diferenciar dois níveis de intensidade do sinal de retorno; e a resolução temporal que se refere ao intervalo de tempo entre a aquisição de duas imagens de uma mesma área (NOVO, 1989).

Dessa maneira, sensores remotos são sistemas fotográficos ou óptico-eletrônicos capazes de detectar e registrar, sob a forma de imagens ou não, o fluxo de energia radiante refletido ou emitido por objetos distantes. Mas**,** todos os materiais e fenômenos naturais absorvem, transmitem, refletem e emitem seletivamente radiação eletromagnética. O desenvolvimento atual dos sensores permite medir com razoável precisão e remotamente, as propriedades espectrais destes materiais e fenômenos.

2.2.1 Sensor IKONOS II

Há alguns anos as resoluções espaciais do sistema sensor só variavam de 30 metros a, no máximo 10 metros, resoluções estas denominadas hoje respectivamente, baixa e média resoluções. Com os avanços em pesquisas no ramo dos sensores, atualmente estão surgindo satélites, cujos sensores são denominados de alta resolução (MOREIRA, 2003).

O sistema sensor IKONOS II é um exemplo desta nova geração de satélites. As imagens produzidas por ele possuem resolução espacial de 1 metro no modo pancromático e 3 metros nas bandas que operam no espectro visível e uma no infravermelho. Foi lançado no dia 24 de Setembro de 1999 e está funcionando desde o início de janeiro de 2000.

Ele é operado pela Space Imaging[1] que detém os Direitos de Comercialização mundialmente. As principais características técnicas do sensor IKONOS II estão resumidas na tabela 01.

[1] Maiores informações sobre a empresa e seus produtos no site: *www.spaceimaging.com*.

Tabela 01: Características do sensor IKONOS II

Bandas	Resolução Espectral	Resolução Espacial	Resolução Temporal	Resolução radiométrica
Azul	0,45 a 0,52 μm	4 metros	1,5 dia	8 e 11 bits
Verde	0,52 a 0,60 μm	4 metros	1,5 dia	8 e 11 bits
Vermelho	0,63 a 0,69 μm	4 metros	1,5 dia	8 e 11 bits
IVP	0,76 a 0,90 μm	4 metros	1,5 dia	8 e 11 bits
Pancromática	0,45 a 0,90 μm	1 metro	2,9 dias	8 e 11 bits

IVP = Infravermelho
fonte: adaptado de Moreira, 2003

Devido a alta resolução das imagens produzidas pelo sensor IKONOS, ele pode ser usado em (MOREIRA, 2003):

- Sistema de Informação Geográfica (SIG) - (redes, telecomunicação, planejamento e meio ambiente);
- Elaboração de mapas urbanos;
- Mapas de arruamento e atualização de cadastro;
- Uso e ocupação do solo;

A alta resolução do IKONOS modificou até a forma de utilização das imagens por ele geradas. Anteriormente um pixel continha vários objetos, atualmente**,** um objeto contém vários pixels (MOREIRA, 2003).

As imagens são fornecidas em arquivos digitais, com diferentes especificações, de acordo com as necessidades dos usuários. A amplitude da cena, de 11 por 11 quilômetros, estabelece uma relação muito mais favorável para os custos das cartas produzidas a partir de imagens. As imagens IKONOS são produzidas segundo diferentes níveis de processamento, Geo, Geo Orto, Reference, Map, Pro, Precision e o Precision Plus. Sendo todos com 1 metro de resolução espacial pancromática ou 4 metros multispectral, porém submetidos a tratamentos

diversos para atender finalidades distintas, e que correspondam também, a diferentes custos de aquisição (ISHIKAWA, 2001).

Assim, com o desenvolvimento dos sensores de alta resolução espacial como o sistema IKONOS de 1 metro, surgiu a possibilidade de separar os objetos da paisagem urbana, como casas e ruas, provocando uma revolução não apenas nos processos de geração e manutenção de bases cartográficas, mas também, nos processos clássicos de classificação de imagens (NISHIDA, 1998 apud ANDRADE et al, 2003).

2.3 Alvos Intra-Urbanos

Para que sejam extraídas informações a partir de dados de sensoriamento remoto é necessário conhecer o comportamento espectral dos alvos. A determinação da natureza dos alvos pelos métodos de sensoriamento remoto é baseada no fato de que diferentes materiais são caracterizados por reflectâncias próprias, em cada banda do espectro. A reflectância é a razão entre o fluxo incidente e o fluxo refletido (NOVO, 1989).

Assim é importante o conhecimento do comportamento espectral de alvos não somente para a extração de informações de imagens obtidas pelos sensores, mas também para a definição dos novos sensores e do tipo de processamento a que devem ser submetidos os dados brutos ou mesmo a forma de aquisição desses dados, já que o arranjo espacial dos alvos na cena interfere na sua detecção (NOVO, 1989).

Segundo Novo (1989), um problema enfrentado, nesse sentido, é que analisar uma curva espectral de um objeto é uma tarefa relativamente simples,

entretanto, os objetos estão inseridos num contexto, sofrendo interferências múltiplas, quer oriundas de objetos adjacentes, quer oriundas do próprio dinamismo interno de suas características. Segunda a mesma autora, outro aspecto importante é a distribuição espacial dos objetos, uma vez que os dados disponíveis são registros de intensidades numa cena.

Esses problemas são facilmente observáveis quando se trabalha com o espaço intra-urbano. No espaço intra-urbano há uma variedade de curvas espectrais de vários alvos que devido a sua semelhança espectral e aos problemas mencionados anteriormente, tornam ainda mais difícil o trabalho de discriminar alvos dentro desse espaço.

Porém, Herold et al. (2002) em um de seus experimentos de comparação do comportamento espectral de alvos intra-urbanos em bandas dos sensores ETM+ do LANDSAT, IKONOS e AVIRIS (sensor hiperespectral aerotransportado), comprovaram que existem importantes bandas de diferenciação dos alvos urbanos em comprimentos de onda do infravermelho próximo e médio. Estas bandas não estão disponíveis nos sensores IKONOS e LANDSAT.

Na Figura 1 é possível observar as curvas espectrais para cada feição urbana. Observa-se também que as feições rodovia de asfalto escuro (dark asphalt road) e estacionamento (parking lot) possuem curvas muito próximas em todo o espectro visível e no início do infravermelho próximo, sendo diferenciados somente a partir de 1,2 µm aproximadamente, sendo que neste comprimento de onda não há nenhuma banda espectral no satélite IKONOS. Desta forma, o referido sensor ainda não é capaz de produzir dado que permita diferenciar estas duas feições.

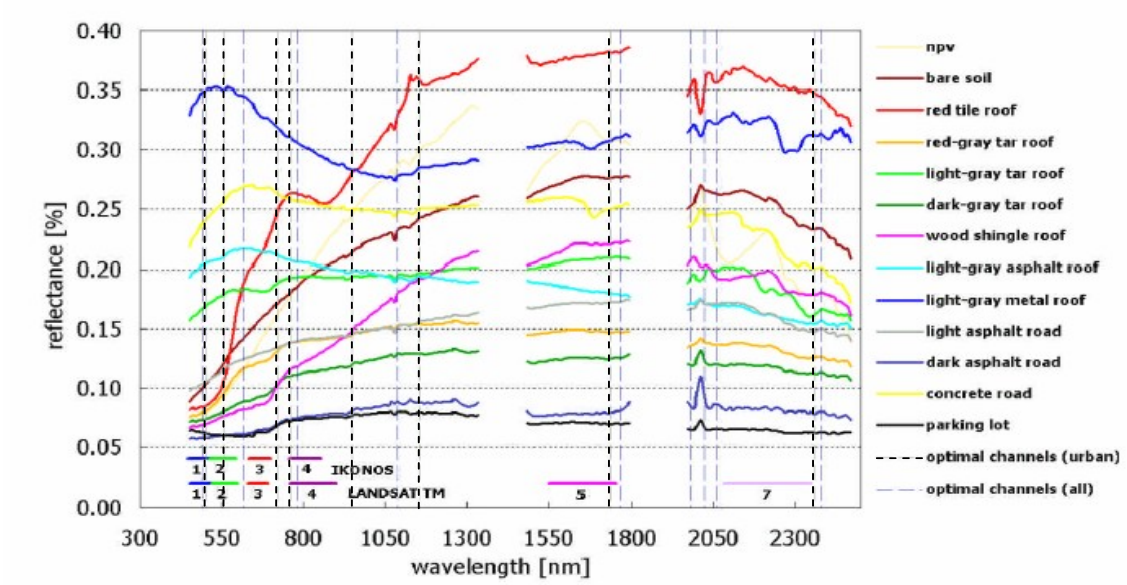

FIGURA 1: Assinaturas espectrais de tipos de cobertura urbana a partir do sensor AVIRIS. As melhores bandas de separação para cobertura urbana são destacadas por linha verticais pretas e em cinza para o restante dos tipos de cobertura.
FONTE: (HEROLD et al., 2002)

2.4 Classificação de Imagens

Classificação é o processo de extração de informação a partir de imagens para reconhecer padrões e objetos homogêneos. A discriminação e posterior identificação desses padrões é possível devido aos diferentes objetos da superfície terrestre que apresentam um comportamento espectral específico, podendo, na maioria das vezes, ser quantificado, permitindo assim que o objeto seja identificado por sua assinatura espectral. Segundo Schowengerdt (1997), a classificação de imagens é o processo utilizado para produzir mapas temáticos a partir das mesmas. As classes temáticas são padrões e objetos homogêneos, segundo os atributos de interesse da classificação (SCHOWENGERDT, 1997). As técnicas de classificação digital implicam na implementação de um processo de

decisão para que o computador possa atribuir certo conjunto de pontos da imagem (objetos) a uma determinada classe.

A classificação de objetos ou fenômenos é feita pela escolha das características que os descrevem para diferenciá-los entre si. As técnicas de classificação digital teriam, dessa forma, o objetivo de 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).

Os métodos de classificação estão basicamente divididos em três conjuntos: a classificação supervisionada, a não-supervisionada e a híbrida. Na classificação supervisionada, o classificador orienta sua busca de classes a partir de amostras de treinamento feitas anteriormente com as classes de interesse da cena. Na segunda, o classificador separa classes espectralmente semelhantes pertinentes à cena (NOVO, 1989). A híbrida são classificações em que o analista utiliza uma classificação não supervisionada como base para a seleção de elementos amostrais de treinamento para realizar a classificação supervisionada (NOVO, 1989).

A classificação de imagens de alta resolução é uma questão desafiadora, principalmente se o que se quer extrair são informações referentes a áreas intra-urbanas com uma grande quantidade de detalhes. Para retirar tais informações é necessário atentar para aspectos de tonalidade e textura em diferentes escalas para cada objeto na cena (MOHAN et al, 2003). Escala neste caso está associada à quantidade de detalhes contidos no objeto. No entanto, em alguns processamentos é necessário atentar para a organização e estrutura do alvo a ser extraído.

A classificação pode então ser feita de maneira automática, ou não automatizada. A classificação automática é realizada por meio computacional havendo algum tipo de intervenção humana nas classificações realizadas pelo computador e na última, a classificação baseia-se na interpretação de imagens.

A interpretação de imagem é uma técnica onde o analista descreve as classes de mapeamento em função dos aspectos visuais reconhecidos na imagem, podendo haver ou não a utilização de computadores. Nesta pesquisa foi utilizada a classificação semi-automática por meio de análise orientada ao objeto, isto é, após a classificação automática é permitido que o analista interaja e, se necessário, faça correções no resultado final sem comprometer a classificação.

Porém todos os tipos de classificações de imagens precisam ter um projeto de classificação. Jensen (1996) descreve os passos gerais usados para extrair informação de cobertura da terra de dados de sensoriamento remoto digital como:

1- Há um problema que precisa ser classificado: são definidas as regiões e as classes de interesse. Normalmente essa fase é realizada por interpretação visual de imagem ou visitas a campo.

2- São adquiridos os dados apropriados de sensoriamento remoto e referência no terreno.

3- Processamento da imagem para extrair informações temáticas: nessa etapa são feitas as correções geométricas, radiométricas entre outras e selecionado o algoritmo e a lógica de classificação da imagem.

4- Avaliação do erro no mapa de classificação de cobertura da terra: é apreciada a qualidade de confiança que o mapa tem se comparado ao real.

5- Distribuição dos resultados caso a acurácia seja aceitável.

Segundo Congalton e Green (1999), processos de classificação são fundamentais para quaisquer projetos de mapeamento, pois ao seguir um projeto se reduz o número de objetos que deverão ser, posteriormente, manipulados, pois estes estarão agrupados em classes de análise.

Durante o processo de classificação um dos primeiros itens a serem definidos é a legenda. Uma legenda é a aplicação de um sistema de classificação numa área específica onde serão utilizados uma escala de mapeamento definida e um conjunto de dados específicos. Uma legenda, então, pode conter somente uma porção ou um subconjunto de todas as classes possíveis da classificação. Assim, a legenda é:

- uma representação dependente da escala e simbologia cartográfica e;
- dependente da metodologia de mapeamento e dos dados.

2.4.1 Interpretação da imagem

O primeiro passo de um processo de classificação é definir, de acordo com o problema, classes de interesse. Para realizar essa etapa é necessário retornar ao processo amplamente conhecido como interpretação de imagens. A interpretação de imagens orbitais ou foto-interpretação depende do conhecimento do analista ou foto-intérprete e consiste em extrair informações de alvos da superfície terrestre, com base nas suas respostas espectrais, quando observados na imagem (MOREIRA, 2003). Para realizar a interpretação de imagens são necessários alguns elementos, tais como: textura, forma, tamanho, tonalidade ou

cor etc, que servem de auxílio para distinguir um objeto dos demais dentro de uma cena específica.

Além dos elementos de interpretação de imagens e dos dados relacionados ao sensor utilizado, o intérprete de imagens deve empregar dados auxiliares necessários para melhorar os resultados da interpretação da imagem. O tipo de material auxiliar depende da área de interesse do especialista (MOREIRA, 2003). No caso de mapeamento de favelas, esses dados podem ser mapas de localização das favelas, censo local etc. Além disso, os resultados da interpretação visual devem ser expressos numa unidade cartográfica conhecida e aceita pela comunidade em geral, explícitos por meio de uma legenda.

2.4.1.1 Elementos de interpretação

Para realizar qualquer interpretação de imagens é necessário conhecer o objeto que se quer interpretar. Alguns elementos norteiam esse conhecimento como o padrão, a tonalidade ou cor, a forma, o tamanho, a textura e localização no contexto das feições. Estes elementos organizados em chaves de interpretação são importantes para se distinguir quais feições na imagem pertencem a qual classe, bem como quais classes existem naquele local específico. Abaixo são descritos detalhadamente cada elemento anteriormente citado.

Padrão: é uma característica dos objetos feito pelo homem e de algumas ocorrências naturais (GARCIA, 1982). Refere-se ao arranjo espacial de determinados objetos em uma superfície. Dessa maneira, uma área residencial planejada pode ser distinguida de uma área de ocupação irregular pelo seu padrão espacial de quadras regulares, afastamento entre lotes etc (FLORENZANO, 2002).

Tonalidade e Cor: Numa foto ou numa imagem de satélite, as diferentes quantidades de energia refletidas pelos alvos são associadas a tons de cinza, ou seja, quando o objeto reflete muita energia, a quantidade recebida pelo sensor é grande. Neste caso, associa-se a esta quantidade de energia um nível de cinza-claro e vice–versa (MOREIRA, 2003). Para Florenzano (2002), cor é o resultado da combinação da resposta espectral dos alvos em uma determinada banda e do tipo de composição colorida utilizada para a imagem em uso.

A cor é empregada no lugar da tonalidade, porque os olhos humanos estão mais habituados a enxergar objetos coloridos do que objetos em tons de cinza.

Forma: Pode-se considerar a forma como uma expressão topográfica ou de contornos e é tão importante que alguns objetos são identificados apenas por este elemento (GARCIA, 1982). O conhecimento da forma de um objeto no mundo real é muito importante para auxiliar o intérprete de imagens na sua identificação, quando observado numa foto aérea ou imagem de satélite, embora outros alvos da superfície também apresentem formas semelhantes (MOREIRA, 2003). Um bom exemplo são as culturas irrigadas por pivô central que se diferenciam das demais culturas por sua forma circular.

Tamanho: O tamanho ocorre em função da resolução espacial da imagem analisada e da dimensão dos objetos na cena (FLORENZANO, 2002). Em interpretação de imagens é comum utilizar o tamanho dos alvos como critério de identificação. Por exemplo, áreas agrícolas têm formas regulares e bem definidas, pois as culturas são plantadas em linhas. Todavia, o tamanho das áreas destinadas ao plantio de hortaliça é muito menor do que as do plantio de cana-de-açúcar, arroz ou milho.

Textura: a textura é criada pela repetição tonal de grupos de objetos algumas vezes muito pequenos para serem vistos individualmente. Embora com muitas limitações, a textura tem sido definida como grosseira, fina, áspera, aveludada etc, porém essa análise é bem subjetiva (GARCIA, 1982). Este elemento distingue, por exemplo, tipos de vegetação (MARCHETTI e GARCIA, 1977; FLORENZANO, 2002) e redes de drenagem (GARCIA,1982).

Localização no contexto: Diz respeito ao local específico onde uma feição está situada e seu relacionamento com os demais. Este atributo pode ser utilizado para identificar um tipo específico de bioma em uma determinada localização geográfica.

Na área urbana, bem como em áreas faveladas, os elementos que melhor distinguem seus alvos são a cor, a forma, o padrão, o tamanho e a localização. Uma associação destes elementos de interpretação auxilia na separação dos alvos e caracterização dos mesmos dentro de uma determinada cena.

2.4.1.2 Chave de interpretação

Num processo de interpretação de imagem a separação das classes é feita por associação, levando em consideração os elementos de interpretação. Essas associações são denominadas chaves de interpretação. Dentre os tipos de chave de interpretação existentes (para mais detalhes ver MOREIRA, 2003) tratar-se-á aqui do tipo de chave de interpretação pelo método sistemático.

Método sistemático

Esse método consiste em aplicar uma metodologia em uma seqüência lógica de etapa de foto-interpretação, isto é: foto-leitura, foto-análise e foto-interpretação. A interpretação visual da imagem pelo método sistemático ocorre da seguinte maneira (MOREIRA, 2003):

- Metodicamente – é feita a interpretação de um tema de cada vez. Por exemplo, toda área ocupada por telhados cerâmicos.
- Do geral para o particular – neste caso, cada classe pode conter várias subclasses. Por exemplo, a cana-de-açúcar pode ser composta das subclasses cana adulta, cana colhida e cana nova.
- Do conhecido para o desconhecido – é feito o mapeamento das classes conhecidas, como mata ciliar, cidades, barragens, estradas, mata natural e pastagem.
- Convergindo evidências – a interpretação visual é produzida com base em certos critérios que evidenciam a presença do alvo que se está investigando. Nessa fase, para discriminar alvos parecidos são utilizadas evidências baseadas, principalmente, na forma e vizinhança.

2.4.2. Interpretação de imagens baseadas em conhecimento

Cognição é um conceito vastamente usado por psicólogos e pedagogos para atividades mentais de como utilizar a linguagem, raciocinar, resolver problemas, emitir e compreender conceitos, recordar e imaginar (ANTUNES, 2003). Dessa maneira, perceber é um processo que se desdobra em

várias etapas desde a visualização até a análise baseada no conhecimento prévio (FRANK, 1998).

Para então realizar essa interpretação em uma imagem, de acordo com Bähr (2002), o cérebro humano realiza as seguintes etapas: visualização, reconhecimento e análise. A visualização se refere a parte em que temos contato com o objeto. O reconhecimento é baseado no conhecimento prévio, que permite distinguir objetos e suas relações com os demais. O processo de análise é o mais complexo dos três, pois requer que as relações de contexto sejam introduzidas no processo. Essa modalidade de interpretação se aproxima do raciocínio humano, por conseqüência, próximo ao mundo real.

O processo de interpretação está associado, deste modo, diretamente com nosso cérebro que tende a agrupar coisas similares formando objetos. Segundo Antunes (2003), esta capacidade de agrupamento é tão apurada quanto maior for a base do conhecimento e melhor definido o objetivo a ser alcançado.

Segundo o mesmo autor, o conhecimento pode, ainda, ser representado hierarquicamente por meio de uma estrutura que relaciona objetos e regiões em termos de semântica. Semântica segundo o Dicionário Aurélio (2003), é o estudo das relações entre sinais e símbolos e o que eles representam. Assim estudar a semântica dos objetos, significa estudar o que são e o que representam no espaço hierarquicamente organizado de forma lógica.

Jansenn e Molenaar (1995), descrevem que as características semânticas dos objetos podem ser analisadas de acordo com aspectos geométricos (topologia, forma e posição) e temáticos (atributos não-espaciais dos objetos).

Com base nesse tipo de interpretação foram criados os sistemas baseados em conhecimento. Estes são aqueles que modelam, em um ambiente computacional, o conhecimento que o intérprete de imagens orbitais adquiriu, imitando a sua capacidade de combinar dados de diferentes fontes e formatos na análise de imagens de sensores remotos (FEITOSA et al, 2005).

Ao contrário da classificação pixel a pixel, na abordagem baseada em conhecimento o objetivo é identificar objetos e aplicar as chaves de interpretação que expressam características de cor, forma, textura e contexto na imagem analisada, tornando assim, a abordagem mais eficaz porque seu resultado se aproxima das feições reais no terreno.

O sistema concebido baseado em conhecimento é antigo, mas a pouco esse conhecimento foi implementado em softwares comerciais. O primeiro software comercial que implementou um sistema de interpretação de imagens com essa modalidade de sistema, ou seja, interpretação de imagens baseada em conhecimento foi o eCognition da empresa Definiens (DEFINIENS, 2004). Aqui ele é utilizado para efetuar a classificação de cobertura do solo para áreas de favela.

2.5 Análise Orientada a Objeto

2.5.1 Conceito de objeto

Objetos são feições do terreno que podem ser reconhecidas no domínio da imagem, como polígonos das mais variadas formas (ANTUNES, 2003).

Cada objeto é único sendo definido conforme as suas características geométricas, de forma e topologia e pelas suas características não-geométricas, de comportamento espectral, de elevação altimétrica no terreno, do tipo de solo, dentre outras (ANTUNES, 2003).

2.5.2 Abordagem orientada a objetos

A abordagem da classificação orientada ao objeto procura classificar a informação presente na imagem a partir do desenvolvimento das relações estabelecidas entre as entidades encontradas, entendendo uma imagem como um espaço próprio de construção e representação da realidade. A classificação é assim entendida como um produto da delimitação de fronteiras não apenas de corpos singulares e homogêneos, mas sim como o produto que resulta do entendimento de novas concepções de espaço com diferentes propriedades e objetos (ENCARNAÇÃO et al., 2005).

Neste sentido, a diferença de um objeto singular em relação a outros espacialmente relacionados, é definida pela inserção de atributos de aproximação ao objeto real, como a textura, a localização relativa e o contexto espacial. Então, pode-se dizer que a criação de redes de objetos origina uma tipologia de classes hierarquizadas, em várias escalas, numa abordagem sistemática e representativa do território.

Para realizar esse tipo de abordagem tem-se que pensar em duas etapas: a percepção, a tomada de decisão. A percepção é a fase em que o intérprete identifica formas, texturas, cores e padrões de organização, formulando então a estrutura do método para interpretação da imagem. As tomadas de decisão são baseadas na definição das funções que melhor associam cada objeto a uma determinada classe. A função é a simplificação semântica do objeto entendido como um todo, determinada pelas partes constituintes desse mesmo objeto, que em um nível conceitual, apresentam uma infinita possibilidade de opções combinatórias de desfragmentação (ENCARNAÇÃO et al, 2005).

Os processos de automatização tradicionais recorrem a análises de imagens pela utilização de algoritmos de classificação dos padrões espectrais ou texturais desta imagem, que atribuem os dados captados pelos sensores a classes de uso e ocupação do solo. Sendo assim, uma análise pixel a pixel torna difícil o seu uso para atualização de mapas com unidade cartográfica mínima superior a área do pixel.

Por outro lado, a classificação de imagens por pixel apenas considera os valores espectrais, enquanto um intérprete de imagens leva em conta o tamanho, a forma, a vizinhança e o conhecimento local ou fenômenos quando classifica o objeto que visualiza. A classificação visual de imagens lida com a sua semântica. Na maioria dos casos, a informação semântica não se aplica ao pixel, mas aos objetos e as relações entre eles.

Esse tipo de abordagem tem por vantagens: objetos com tamanho superior ao do pixel facilitam a integração com mapas já existentes e a respectiva atualização destes. Possibilita considerar a textura, forma e contexto na

classificação (BLASCHKE e STROBL, 2001) e o recurso das semânticas estruturadas.

Segundo Antunes (2003), no processo de classificação, o contexto entre os objetos está vinculado à análise de relacionamentos de uma classe com a outra, isto é, a classe A só existe se estiver topologicamente relacionada a uma classe C. Assim, o mesmo autor define que a topologia é utilizada quando se deseja implementar relações entre polígonos gerados a partir do agrupamento de pixels, descrevendo propriedades espaciais de área afim de que os atributos não-espaciais associados aos elementos poligonais possam ser manipulados.

De acordo com Antunes (2003), os relacionamentos espaciais entre os objetos podem ser explicitados pelas seguintes relações topológicas: conectividade, adjacência, disjunção e contingência.

Conectividade de acordo com Molenaar, citado por Antunes (2003), são objetos estruturados topologicamente e significa que quaisquer dois objetos O_i e O_j estão conectados se $O_i \cap O_j \neq o$.

Adjacência: Dois objetos $f_1 \; e \; f_2$ são adjacentes se estes compartilham um limite e_i.

Disjunção: é definida quando não existe limite comum entre os objetos $O_i \cap O_j = o$.

Contingência: compreende as relações entre objetos contidos em outros objetos.

Dessa maneira o conceito de vizinhança está baseado nas relações topológicas dos objetos. E os objetos criados na imagem devem ajustar-se aos objetos da realidade, tanto no nível de sua geometria (limite, forma etc.), como em sua semântica (conteúdo, significado e outros).

A abordagem orientada por objetos assemelha-se à percepção humana na forma como a visão humana extrai a informação que é baseada em objetos (BLASCHKE et al., 2000). Primeiro, a percepção de áreas homogêneas, ou objetos, são posteriormente caracterizadas por uma rede complexa de experiência e conhecimento. De maneira semelhante, a análise orientada por objetos é executada em duas etapas: a segmentação e a classificação. Na segmentação são criados os objetos que servem de base para uma classificação. BAATZ e SCHÄPE (1999), propuseram um algoritmo denominado segmentação por multi-resolução que é um tipo de segmentação por crescimento de regiões (Fractal Net Evolution - FNEA).

2.5.3. SEGMENTAÇÃO

O primeiro passo em análise de imagem, geralmente, é a segmentação. Esta subdivide uma imagem em regiões ou objetos (GONZALEZ e WOODS, 1992). É nessa etapa do processo que é determinado o eventual sucesso ou fracasso da análise.

Algoritmos de segmentação geralmente são baseados em dois princípios básicos de valores de nível de cinza: a descontinuidade e a similaridade entre os níveis digitais (GONZALEZ e WOODS, 1992). Na primeira categoria, a partição da imagem é baseada em mudanças abruptas de nível de cinza. Já na segunda categoria considera-se similaridade por limiar e por crescimento de regiões.

2.5.3.1 Segmentação orientada a regiões

De acordo com Gonzalez e Woods (1992), o crescimento de regiões é uma técnica de agrupamento espacial na qual somente pixels adjacentes, contíguos na imagem, podem ser agrupados. Esta técnica consiste em partir de um ou vários pixels considerados uniformes, analisar os pixels na vizinhança e adicionar os vizinhos que forem similares ao grupo inicial, de maneira que a região formada cresça num processo iterativo e que seja finalizada quando as fronteiras naturais dos objetos presentes na cena forem atingidas. Ao final do processo, a imagem está dividida em várias sub-regiões (ANTUNES, 2003).

De acordo com Gonzalez e Woods (1992), o processo de segmentação pode ser analisado como subdivisão de **I** em **n** sub-regiões:

1. $\cup_{i=1}^{n} Ri = R$, onde todos os pixels pertencem a uma única região;
2. **Ri**, região conexa, i=1, 2, 3... n;
3. As regiões devem ser disjuntas, tal que, **Ri** $\cap$ **Rj = Ø** para todo i e j, i≠j;

Os pixels em **Ri** de uma mesma região devem possuir a mesma intensidade ou característica;

4. **P(Ri)= verdadeiro** para i= 1, 2,..n e para diferentes regiões **P(Ri**$\cup$**Rj)= falso**, para i≠j. Em que **P(Ri)** é um predicado lógico sobre os pontos do conjunto **Ri** e **Ø** é o conjunto vazio;

A primeira condição sugere que a segmentação deve ser completa. A segunda condição requer que pixels de uma mesma região devem ser conexos.

A região cresce através da agregação de pixels com características similares como cor e brilho (ANTUNES, 2003). A agregação forma o objeto ou região, sendo interrompida quando não pode mais crescer, devido aos parâmetros associados e ao limiar proposto (GONZALEZ e WOODS, 1992).

2.5.3.2 Segmentação por multiresolução

Devido ao fato das estruturas na natureza aparecerem em diferentes níveis de detalhe (BLASCHKE et al., 2000), o processo da segmentação por multiresolução é adequado para análises orientadas a objetos, pois permite criar uma estrutura hierárquica de objetos significativos. De acordo com Medeiros (2003), a idéia não é generalizar ou suavizar imagens em diversas escalas, mas procurar analisá-las como um todo, através de diferentes escalas.

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. Essa técnica segue um modelo cognitivo para agrupar os objetos ou segmentos de características semelhantes podendo ser agrupados formando regiões ou super-objetos. As regiões e/ou objetos que representam o mundo real possuem relações que podem ser expressas por um modelo semântico, de forma a exprimir a visão humana do arcabouço espacial (VORWERG e RICKHEIT, 1998 apud ANTUNES, 2003).

A rede semântica consiste em uma notação gráfica que representa o conhecimento através da conexão de arcos e nós (ANTUNES, 2003). Durante a segmentação é possível relacionar objetos vizinhos e estabelecer relações entre

classes progenitoras e descendentes. Um exemplo desse conceito é que um conjunto de lotes (subobjetos) tornam-se uma quadra (super-objeto) (figura 2).

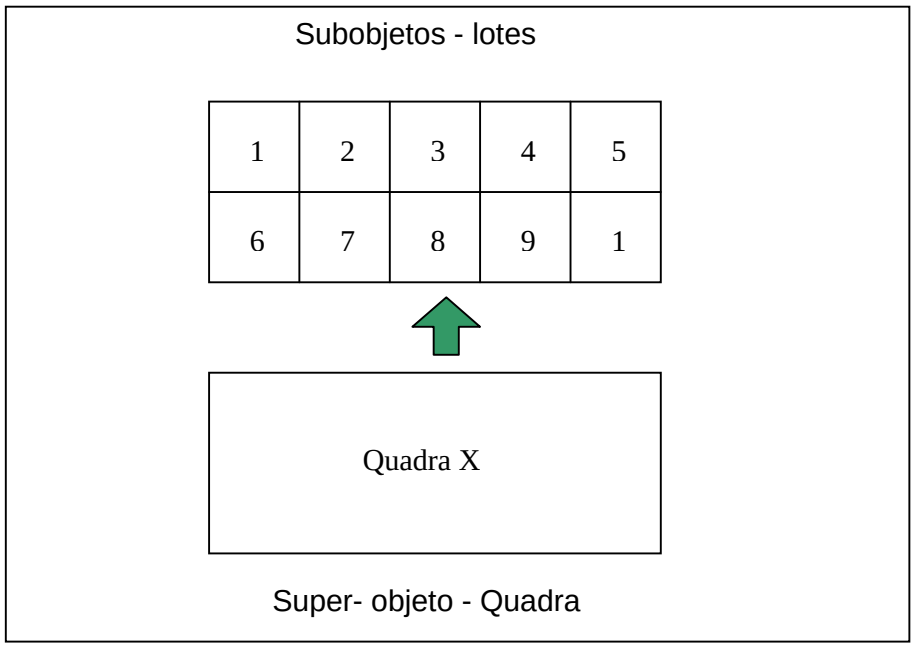

Figura 2: Ilustração dos conceitos de super-objeto e sub-objeto, utilizando como exemplo a relação existente entre lotes e quadras

A segmentação por multiresolução foi idealizada por Baatz e Schäpe (2000), utilizando a noção de evolução de rede fractal (FNEA), na qual os objetos na imagem de sensoriamento remoto são considerados como de natureza fractal[2], que permite segmentar uma imagem em diferentes níveis de segmentação mantendo uma determinada hierarquia entre eles.

Esses níveis são estabelecidos de acordo com o conceito de multi-escala e o fator de escala, dessa maneira, determina o tamanho dos objetos. Para

[2] De acordo com ANTUNES (2003), **fractal**: refere-se a representação de imagens através de frações de objetos ou superfícies irregulares como nuvens montanhas e objetos irregulares, etc., utilizando-se de procedimentos matemáticos que tratam dimensões fracionárias (infimamente pequenas). Um objeto é um fractal se a dimensão Hausdorff-Besicovitch excede a dimensão Euclidiana, sendo fractal um objeto que possui detalhes em todas as escalas espaciais.

encontrar o melhor fator de escala de segmentação, é necessário realizar testes até que os parâmetros apropriados sejam encontrados (MEINEL et al, 2001). Ao segmentar a imagem, simultaneamente, de níveis fino a grosseiro são originadas escalas de segmentação.

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, onde a importância relativa dos parâmetros espectrais e de forma é definida por meio de pesos que variam entre 0 e 1.

Na segmentação multiresolução é possível utilizar duas estratégias para gerar a rede hierárquica de objetos: Bottom-up (de baixo para cima), o processo começa por um nível mais detalhado de objetos que são agregados em objetos maiores conforme o nível hierárquico; e Top-down (de cima para baixo), onde o processo inicia com objetos grandes que são subdivididos até obter o nível de escala mais detalhado.

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, ou seja, cada objeto reconhece os seus vizinhos, subobjetos e super-objetos (DEFINIENS, 2004).

Com isso, para uma boa segmentação são definidas algumas premissas (Definiens, 2004):

1. Um processo de segmentação deve produzir segmentos bastante homogêneos para boa separação de regiões na imagem;
2. Considerando que cada problema de análise de imagem exige diferentes adequações do espaço-escala, o tamanho comum das

escalas deve ser analisado de acordo com os objetos de interesse na imagem;

3. Quase todos os atributos do objeto: cor, textura, forma e relações com regiões adjacentes são dependentes da escala. Somente estruturas com escalas semelhantes podem ser comparadas em termos de qualidade dos atributos;

4. O procedimento deve ser universal e aplicável a um grande número de dados e problemas diferentes;

5. Resultados devem ter a possibilidade de ser reproduzidos por outrem;

6. A observação da terra, frequentemente produz uma grande quantidade de dados. A segmentação deve ser a mais rápida possível.

2.5.4 Rede Hierárquica

A teoria hierárquica foi desenvolvida baseada na estrutura da teoria do sistema geral como um modelo conceitual que constrói a idéia de escalas naturais. Em termos gerais, uma hierarquia pode ser definida como um ordenamento parcial de entidades (SIMON, 1973 apud BLASCHKE et al, 2005). A idéia fundamental é que as feições são objetos (BLASCHKE et al, 2005).

Hierarquias são compostas de subsistemas correlacionados, sendo fragmentados em subsistemas menores até que o menor nível exigido seja obtido. Baseado em hierarquias são formados os conceitos de rede hierárquica, onde o conhecimento pode ser mostrado por níveis de segmentação que contém

informações mais generalizadas nos níveis mais grosseiros (nível 3 – super-objetos) e informação mais detalhada nos níveis mais finos da segmentação (nível 1 – subbjetos). Essa idéia de rede pode ser observada na figura 3, onde está representada uma hierarquia para uma rede qualquer.

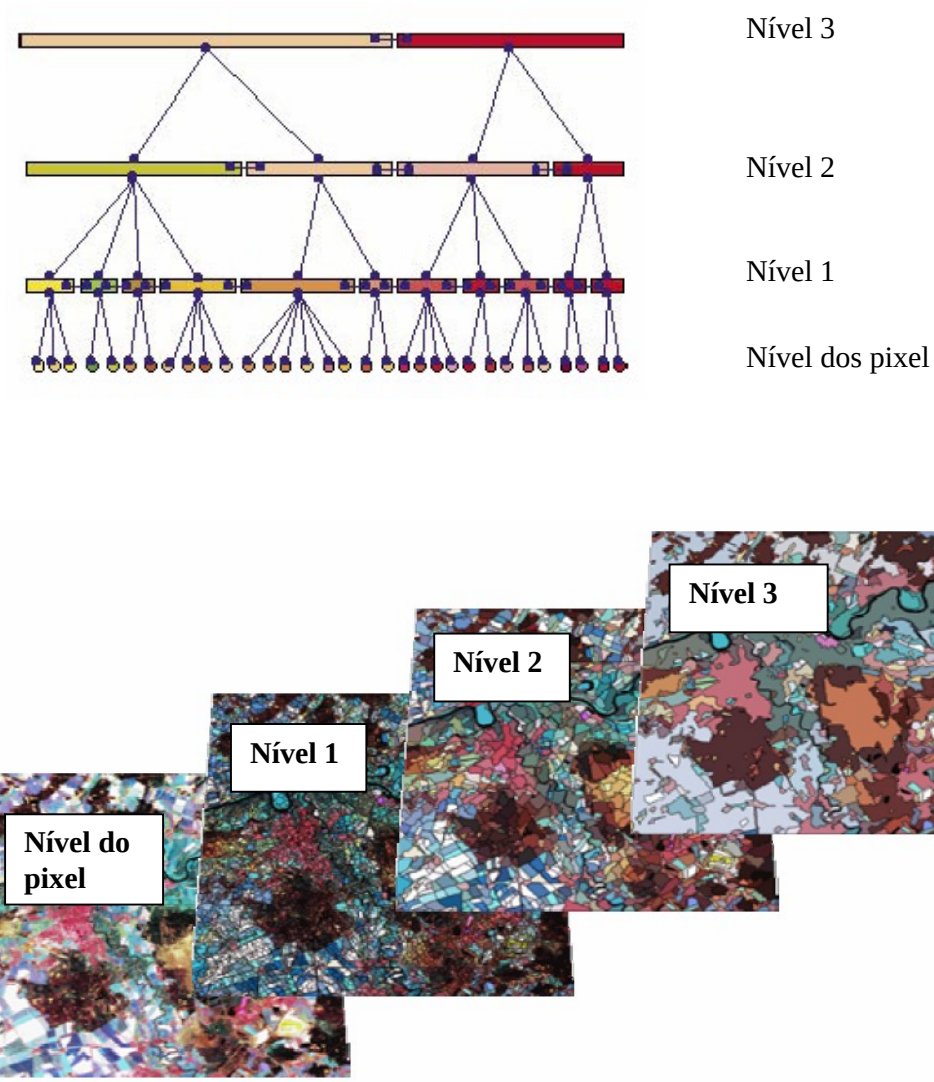

Figura 3: Representação de informação da imagem por meio de uma rede hierárquica de objetos na imagem ligados por meio de arcos e nós de acordo com a semântica dos objetos. Fonte: Adaptado de Definiens, 2004.

Os objetos da imagem são transmitidos em rede de maneira que cada objeto “sabe” a que super-objeto pertence no nível superior, “reconhece” seus subobjetos no nível inferior e detecta seus vizinhos no nível hierárquico que está (Benz et al., 2004). Esta informação topológica pode ser utilizada na classificação dos objetos e constitui uma das maiores vantagens apresentadas pela análise de imagens orientada a objetos (Pinho, 2005).

Começando do nível do pixel, os níveis são numerados de forma consecutiva, seguindo uma abordagem bottom-up ou top-down. Esta rede hierárquica é topologicamente definida, isto é, a borda de um super-objeto é consistente com as bordas de seus subobjetos. A área representada por um objeto na imagem é definida pela soma de seus subobjetos. Dessa forma cada nível é construído baseado em seus subobjetos diretos, ou seja, os subobjetos são agrupados em objetos maiores no próximo nível, sendo que o agrupamento permanece limitado pela borda dos super-objetos (DEFINIENS, 2004).

A hierarquia de classes é uma estrutura da linguagem do eCognition que tem por finalidade formular a base do conhecimento para classificar objetos na imagem e possui todas as classes definidas em um esquema de classificação, hierarquicamente estruturado. Conforme Definiens (2004), as relações dos objetos definidas pela hierarquia de classes são duas: a hierarquia por herança e a por grupos.

Hierarquia por herança é uma técnica comum em modelagem orientada a objeto. A classe “mãe” mais geral transmite propriedades dela para os objetos da classe “filha”, ou seja, as classes “filhas” herdam características da “mãe”.

Hierarquia por grupos a herança permite o agrupamento de classes muito diferentes a uma classe superior de significado semântico comum.

Na estruturação das classes em redes hierárquicas, os objetos e seus relacionamentos são modelados por regras de classificação. Essas regras são baseadas nas funções *fuzzy* de pertinência, que tem por princípio a teoria dos conjuntos *fuzzy* (PINHO, 2005).

2.5.5 Teoria dos conjuntos Fuzzy

Desde 1960, a teoria de conjuntos *fuzzy* vem sendo desenvolvida para ser uma ferramenta prática e útil disponível para uso em várias áreas do conhecimento. Em 1965, Zadeh introduziu a idéia de "conjuntos *fuzzy*" para trabalhar com conceitos inexatos. Conjuntos *fuzzy* admitem a possibilidade de pertinência parcial, que são generalizações dos conjuntos convencionais para situações onde os limites das classes não são ou não podem ser definidos.

Segundo Burrough e Frank (1996), um conjunto *fuzzy* é definido matematicamente como: Se $Z = \{z\}$ denota um espaço de objetos, então o conjunto A em Z é um conjunto de pares ordenados.

$$A = \{z, MF_A^F(z)\}, z \in Z \qquad (6)$$

Onde a função de pertinência $MF_A^F(z)$ é conhecida como o grau de pertinência de z em A e z em Z, significando que z está contido em Z. Usualmente $MF_A^F(z)$ é um número entre 0 e 1, com 1 representando a total pertinência ao conjunto e 0 demonstrando a não pertinência. O valor de $MF_A^F(z)$ do objeto z em A pode ser interpretado como o grau de compatibilidade do predicado associado ao

conjunto A e o objeto z; em outras palavras $MF_A^F(z)$ de z em A especifica a extensão que z pode ser estimado como pertencendo a A (BURROUGH e FRANK, 1996).

A subjetividade é uma modalidade de imprecisão das classes que por vários motivos não podem ou não têm limites rígidos definidos. Essa subjetividade frequentemente está associada a complexidade. É apropriado usar conjuntos *fuzzy* sempre que se lida com ambigüidade, abstração ou ambivalência em matemática ou modelo conceitual para fenômeno empírico (BURROUGH e FRANK, 1996).

Nesse sentido, subjetividade não é um atributo probabilístico, em que o grau de relação de um conjunto é estabelecido por uma dada função de probabilidade estatisticamente definida. Mas admite-se a possibilidade de um indivíduo pertencer a um conjunto ou não (BURROUGH e FRANK, 1996). A avaliação da possibilidade pode ser baseada no conhecimento subjetivo, intuitivo ou de preferência, podendo também definir incertezas que tem base na teoria da probabilidade. Por exemplo, a incerteza em alocação de classes poderia ser estabelecida pela possibilidade de medir erros de certa magnitude.

2.5.6. Classificação orientada a objeto

A metodologia orientada a objeto permite que o usuário interaja com o processo de classificação, 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, como era feito.

A classificação dos objetos, baseada na segmentação por multiresolução (ou multiescala) permite trabalhar com os conceitos de generalização semântica, procurando num nível mais elevado, uma precisão das fronteiras dos objetos, e em níveis mais baixos, a precisão do detalhe interno dos elementos constituintes dos super-objetos. A segmentação por multiresolução permite englobar o conceito de rede hierárquica de objetos, no conjunto de variáveis visuais de cor, textura, forma etc., utilizados na identificação e descrição dos objetos. Na integração de conceitos, admite-se uma associação horizontal e vertical na rede hierárquica, definida pela delimitação e classificação de polígonos.

Num ambiente baseado no objeto, conceitualmente trabalha-se com polígonos e por essa razão podem ser usadas todas essas propriedades estruturais para classificação (BLASCHKE e STROBL, 2001). A adoção de classificação em nível de objetos, reside no fato de que esses representam de maneira mais eficaz as feições de uma cena. As relações entre os objetos podem, de certa forma, contribuir para inserção do conhecimento (ANTUNES, 2003).

Uma característica surpreendente de análise de imagem orientada a objeto é a grande quantidade de informação adicional, que pode ser derivada e baseada em objetos da imagem (DEFINIENS, 2004). E de acordo com Antunes

(2003), o método de classificação orientado ao objeto supera os convencionais por estar mais próximo do raciocínio humano no que se refere aos seguintes aspectos:

- ✓ Objetos são mais facilmente percebidos pelo cérebro humano que pixels;
- ✓ Estabelecem-se relações entre os objetos;
- ✓ Possibilita a introdução do conhecimento a priori;
- ✓ Estruturação lógica de atributos.

2.6 Avaliação da Confiabilidade da Classificação

Segundo Congalton e Green (1999), mapas ajudam a medir a extensão e distribuição dos recursos, analisar interações, identificar locais apropriados para ações específicas (por exemplo, intervenção ou preservação de um local) e planos para eventos futuros. Contudo, decisões efetivas requerem mapas de conhecimento acurado.

Normalmente, a Matriz de Confusão ou de Erros é usada para avaliar o resultado de uma classificação, a fim de verificar a qualidade dos dados contidos nesse mapa. A confiabilidade da matriz de erros depende da amostragem, registro e conhecimento (CONGALTON E GREEN, 1999). Dessa maneira é importante que a amostra de treinamento seja bastante homogênea e representativa da classe de interesse. Normalmente, as amostras de treinamento são selecionadas a partir do conhecimento prévio que o analista tem da cena. Esse conhecimento pode ser teórico (conhecimento do comportamento espectral dos alvos) ou prático (adquirido em visitas ao campo, em análises de imagens orbitais) (NOVO, 1989).

A seleção da amostra tenta fornecer um subconjunto de valores o mais parecido possível com a população que lhe deu origem. A amostragem mais usada é a amostra casual simples, em que selecionamos ao acaso, com ou sem reposição, os itens que farão parte da amostra (MAGALHÃES e LIMA, 2004).

Eventualmente, se tiver informações adicionais a respeito da população de interesse, pode-se utilizar outros esquemas de amostragem mais sofisticados. Por exemplo, se numa cidade se tiver mais mulheres do que homens, pode-se selecionar um certo número de indivíduos entre as mulheres e outro entre os homens. Esse procedimento é conhecido como amostragem estratificada. Outras vezes, pode existir uma relação numerada dos itens da população (uma lista de referência) que permite utilizar a chamada amostragem sistemática em que se seleciona os indivíduos de forma pré-determinada, por exemplo de 8 em 8 ou 10 em 10. Porém, quanto mais complexa for a amostragem maiores serão os cuidados nas análises estatísticas utilizadas, em contrapartida, o uso de esquemas de amostragem mais elaborados pode diminuir o tamanho da amostra necessário para uma boa precisão (MAGALHÃES e LIMA, 2004).

De acordo com Novo (1989), também é importante na seleção dos elementos amostrais que seu tamanho seja grande o suficiente para permitir a estimativa das características espectrais da classe a ser mapeada.

Sendo assim, não é fácil selecionar um tipo apropriado de amostragem para o cálculo da exatidão do mapeamento, assim é difícil gerar uma matriz de erro que seja representativa de todas as classes interpretadas na imagem (MOREIRA, 2003).

Selecionados o tipo de amostragem e o tamanho dessa amostragem parte-se, então, para elaborar a matriz de erro. Uma matriz de erro compara

informações de locais de referência com informações no mapa por um número de elementos amostrais da área. Unidades amostrais são porções do mapa que serão amostradas para avaliação da acurácia. Nessa matriz, usualmente as colunas são tomadas por corretas e o dado de referência e as linhas são usadas para mostrar o que foi classificado no mapa ou na classificação gerada de dados de sensoriamento remoto.

De acordo com Congalton e Green (1999), conforme a figura 4 constrói-se uma matriz de erro com n elementos amostrais distribuídas dentro de k^2 células, onde cada elemento amostral é atribuído a uma das k classes na classificação (usualmente as linhas) e, independentemente, para uma mesma classe k no conjunto de dados de referência (usualmente as colunas). Logo, n_{ij} denota o número de amostras classificadas dentro da categoria i (i=1,2,...,k) na classificação de sensoriamento remoto e categoria j (j=1,2,...,k) no conjunto de referência.

		+i = colunas (referência)			Total da linha
		1	2	k	x_{i+}
i+ = linhas (classificação)	1	x_{11}	x_{12}	x_{1k}	x_{1+}
	2	x_{21}	x_{22}	x_{2k}	x_{2+}
	k	x_{k1}	x_{k2}	x_{kk}	x_{k+}
Total da coluna	x_{+i}	x_{+1}	x_{+2}	x_{+k}	N

Figura 4: Representação da matriz de confusão

Fonte: Congalton e Green, 1999.

A matriz de erro é uma representação da acurácia do mapa porque permite correlacionar a imagem classificada com dados que são tidos por verdade terrestre.

De acordo com Gongalton e Green (1999), a estimativa de acurácia é adquirida pela exatidão global (eg) que é a razão entre a soma de todos os elementos amostrais classificados corretamente pelo número total de elementos. Esta medida é calculada pela expressão:

$$eg = \frac{\sum_{i=1}^{r} x_{ii}}{N}, \qquad (7)$$

onde:

x ii **=** Elementos da diagonal principal

r **=** Número de classes

N **=** Número total de elementos amostrais

A acurácia pode ser analisada individualmente por meio da análise dos erros de inclusão (erros de comissão) e erros de exclusão (erros de omissão) presentes na classificação (GONGALTON e GREEN, 1999). Um erro de comissão ocorre ao incluir um objeto na classe a qual ele não pertence e o de omissão quando um objeto é excluído da classe a que pertence. Na matriz de erro esses valores são obtidos por meio das exatidões do usuário e do produtor.

A exatidão do usuário (eu) é expressa pela razão do número de elementos distribuídos corretamente em uma classe pelo número total de elementos classificados na mesma. Esta medida reflete os erros de comissão na classificação e indica a probabilidade de um elemento amostral agrupado em uma determinada

classe realmente pertencer à mesma (LILLESAND e KIEFER, 1994). É calculada segundo a expressão:

$$eu = \frac{x_{ii}}{x_{i+}}, \tag{8}$$

onde:

x ii **=** Número de elementos classificados corretamente

x + i **=** Total de elementos classificados para uma classe i

A exatidão do produtor (ep) é a razão entre o número de elementos classificados corretamente em uma determinada classe pelo número de elementos de referência amostrados para a mesma classe (LILLESAND e KIEFER, 1994). Esta medida reflete os erros de omissão da classificação sendo expressa por:

$$ep = \frac{x_{ii}}{x_{+i}}, \tag{9}$$

onde:

x_{ii} = Número de elementos classificados corretamente

x_{+i} = Total de elementos de referência amostrados para uma classe i

Dessa maneira, matriz de erro não é simplesmente uma questão de correto ou incorreto e sim onde está o erro e quais classes estão sendo confundidas. Para essa exatidão ser útil, o usuário deve ter confiança de que a avaliação é uma exata representação da verdade terrestre.

2.6.1 Análise *Kappa*

Segundo Congalton e Green (1999), este coeficiente é baseado na diferença entre concordância observada (diagonal principal da matriz de confusão com a concordância entre a classificação e os dados de referência) e a chance de concordância entre os dados de referência e uma classificação aleatória (produto entre os totais marginais da matriz). A equação que fornece o valor de *Kappa* é dada por:

$$\hat{K} = \frac{N \sum_{i=1}^{r} x_{ii} - \sum_{i=1}^{r} x_{i+} x_{+i}}{N^2 - \sum_{i=1}^{r} x_{i+} x_{+i}} \qquad (10)$$

onde:

r = Número de classes

x_{ii} = Número de elementos classificados corretamente

x_{i+} = Total de elementos classificados para uma categoria i

x_{+i} = Total de elementos de referência amostrados para uma categoria i

N = Número total de amostras

Landis e Koch (1977), propõem uma escala de avaliação da qualidade da classificação. Esta escala está exposta na tabela 2.

TABELA 2 – Qualidade da classificação segundo intervalos do coeficiente de concordância Kappa.

Valor do *Kappa*	Qualidade da Classificação
< 0,00	Péssima
0,00 – 0,20	Ruim
0,20 – 0,40	Razoável
0,40 – 0,60	Boa
0,60 – 0,80	Muito Boa
0,80 – 1,00	Excelente

Fonte: adaptado de Landis e Koch (1977)

Uma das vantagens alegadas para uso do Kappa é que ele incorpora a informação dos pixels mal classificados, e não apenas dos bem classificados como a exatidão global.

De forma simplificada, a exatidão global é um índice que superestima a confiabilidade da classificação, e o Kappa é uma avaliação mais adequada.

2.6.2 Grau de instabilidade ou ambigüidade do processo de classificação

Gopal e Woodcock (1994), propuseram o uso de funções *fuzzy* para analisar a possibilidade da ambigüidade existir durante o processo de classificação Nessas análises, a situação de uma classe ser considerada certa e todas as outras erradas, freqüentemente não existe.

Como uma aproximação reconhece que além de um simples sistema de correto (concordância) e incorreto (discordância), ele pode ter uma variedade de respostas tais como: absolutamente certa, boa resposta, aceitável, regular, ruim e muito ruim. O conceito chave de pertencer a uma classe é uma questão de grau. A lógica fuzzy reconhece que, nas margens de classes que dividem um contínuo, um item pode pertencer a ambas as classes em graus diferentes (CONGALTON e GREEN, 1999).

Mas considerando as funções de pertinência oriundas dos conjuntos fuzzy, Laba et. al. (2002), salientam que cada objeto pode possuir associação parcial a determinada classe, logo, o resultado da classificação pode não ser único. Desta forma, a acurácia deverá ser avaliada em termos de incerteza, e neste caso, é descrita pelo grau de um objeto pertencer a duas ou mais classes. Logo quanto maior a proximidade entre os graus de pertinência mais instável é a classificação (ANTUNES, 2003, ANTUNES e LINGNAU, 2005).

Nesta pesquisa foi utilizado o grau de instabilidade (I_a) proposto por Antunes (2003), que é a razão da diferença dos dois maiores graus de pertinência pelo maior grau de pertinência, apresentado na equação 11. 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, já o valor zero indica total incerteza, como pode ser visto na tabela 03.

$$I_a=(b_{c1}-b_{c2})/b_{c1} \qquad (11)$$

onde:

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

b_{c2} - segundo maior grau de pertinência para um classe c_j qualquer;

$c_i \neq c_j$

Os resultados obtidos por esta fórmula permitirão analisar o quanto é ambígua a classificação. A análise será feita de acordo com uma escala de ambigüidades, também proposta por Antunes (2003), conforme indicado na tabela 3.

Tabela 3: Qualidade da Classificação: Índice de Ambigüidades ou instabilidade

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

Fonte: Antunes e Lingnau (2005).

3. MATERIAIS E MÉTODOS

3.1 MATERIAIS UTILIZADOS

Para realização deste trabalho foram utilizadas as seguintes ferramentas e programas:

- Plano Diretor de São José dos Campos - SP;

- Imagens de Satélite IKONOS - Pancromática com 1 metro e 4 canais multiespectral com 4 metros de resolução espacial, cedidas gentilmente pela empresa Imagem de São José dos Campos;

- Softwares ENVI e eCognition que foram cordialmente cedidos para utilização no Instituto Nacional de Pesquisas Espaciais - INPE.

3.2 Procedimentos Metodológicos

Para realizar o mapeamento da cobertura da terra em áreas de favela deve-se ter em mente que o espaço intra-urbano, onde estão dispostas as favelas, são constituídos por alvos heterogêneos e ao mesmo tempo fortemente influenciados em suas refletâncias pelos alvos vizinhos.

Dessa forma, a fim de obter esse mapeamento, uma seqüência de vários procedimentos, que estão dispostos no fluxograma apresentado na figura 5, foram seguidos.

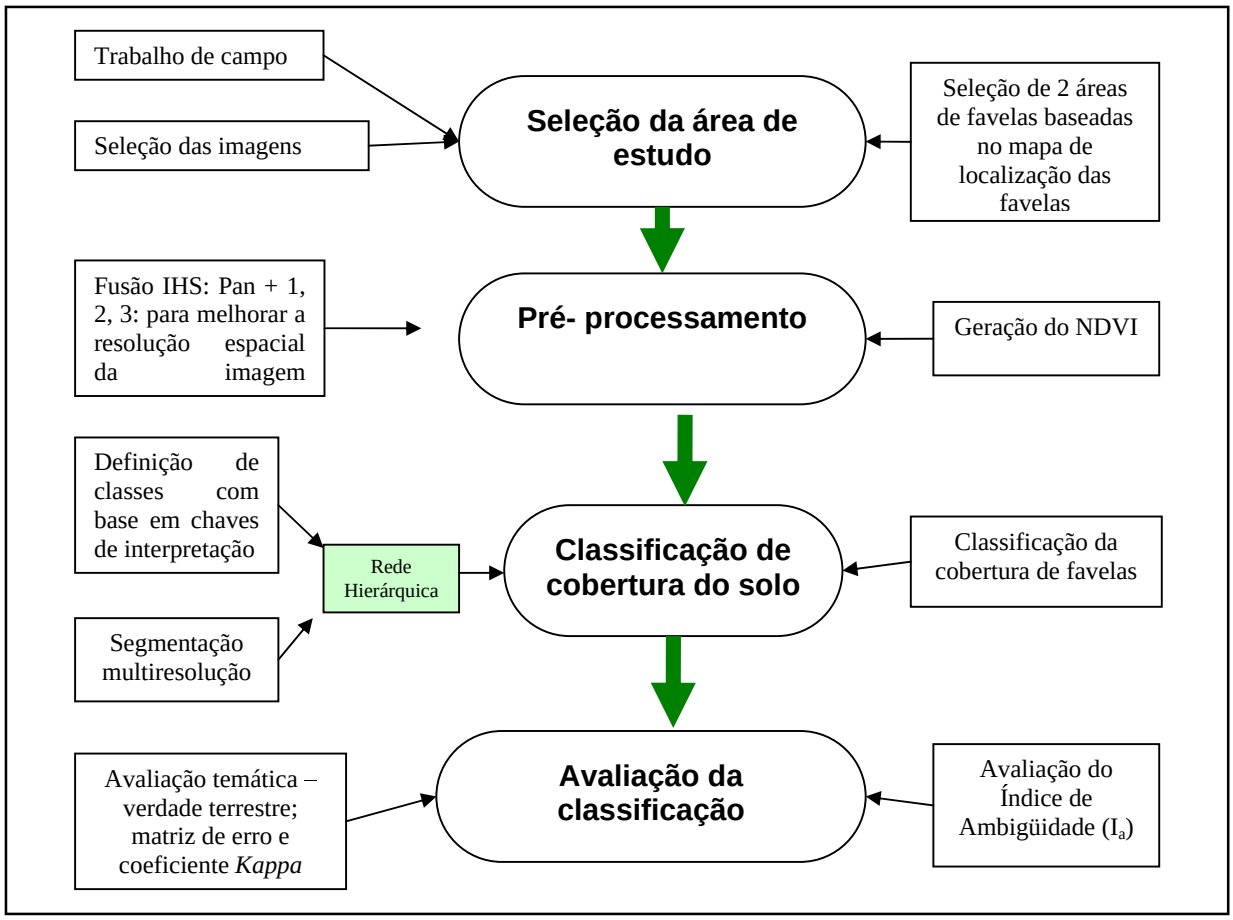

Figura 5: Fluxograma dos procedimentos metodológicos a serem desenvolvidos.

O fluxograma apresentado na figura 5 ilustra as etapas e o desenvolvimento da presente pesquisa.

3.2.1 Trabalho de campo

Foram realizadas três visitas a campo. A primeira para auxiliar na seleção das duas áreas para aplicar o processo de classificação orientado a objeto, bem como detectar as classes ali existentes. A segunda foi efetuada para selecionar na imagem por meio de amostragem aleatória simples, feições que posteriormente serviram como verdade terrestre. Foram então considerados os elementos para

cada classe de acordo com essa verdade terrestre. A terceira foi para analisar visualmente a acurácia temática, ou seja, comparar visualmente o que foi classificado com o que havia no local.

3.2.2 Seleção das Imagens

Para realização deste projeto foi utilizado duas sub-imagens Ikonos da cidade de São José dos Campos – SP, nas bandas pancromática e multiespectrais do satélite IKONOS de 12 de junho de 2002, Georregerenciadas ao sistema de Projeção UTM / WGS84.

3.2.3 Área de Estudo: São José dos Campos: breve histórico

São José dos Campos (figura 6) é um município do Estado de São Paulo, localizado no Médio Vale do Paraíba do Sul, entre as grandes cidades do Rio de Janeiro e São Paulo e várias cidades menores circuncidantes como Jacareí, Guaratinguetá etc. Está situada na Província Geomorfológica denominada Planalto Atlântico. As altitudes variam de 530 a 2000 metros acima do nível do mar (PMSJC, 1994). Este eixo está inserido numa das áreas mais industrializadas e urbanizadas do Brasil (KURDJIAN e VALÉRIO FILHO, 2005). Seu território abrange uma área de 1099.60 km², compreendido entre as latitudes 23°18’S e 22°49’S e longitudes 46°06’O e 45º40’O (PMSJC, 1994).

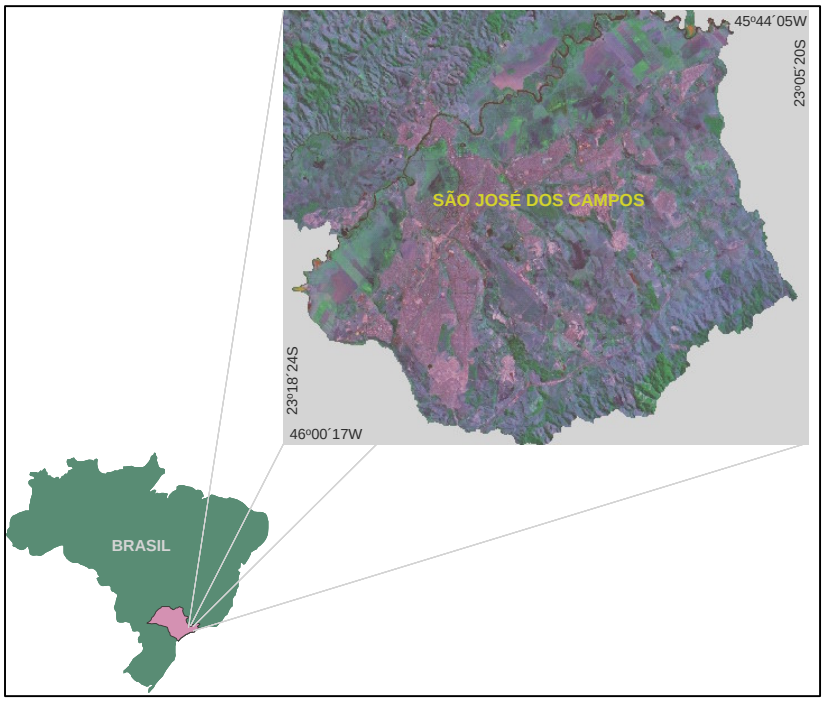

Figura 6: Localização de São José dos Campos – fonte: Prefeitura Municipal de São José dos Campos, 1994.

Em 1980, o município de São José dos Campos representava 1,2% do total da população do Estado de São Paulo e 59% da população de sua Região de Governo. Essa participação aumentou até 2000, passando para 1,5% do total estadual e 63,3% do total regional. Entre 1980 e 2000, a taxa de crescimento populacional da cidade manteve-se acima da média estadual e regional, embora tenha apresentado uma diminuição no período. Na década de 80 a taxa de crescimento era de 3,99% ao ano, caindo para 2,23% ao ano entre 1991 e 2000 (PMSJC, 2004). São José dos Campos, de acordo com os dados censitários, desde a década de 70 sofreu um processo de crescimento acelerado da população urbana. Atualmente, cerca de 98% da população vive na cidade, ou seja, dos 539.313 habitantes, 532.717 residem na área urbana.

O uso e ocupação do solo urbano dessa cidade foram marcadamente influenciados por condicionantes naturais e antrópicos. Dentre os

aspectos naturais, destacam-se o rio Paraíba do Sul e o relevo. O primeiro, com sua extensa várzea, possibilitou a instalação de atividade agrícola às suas margens, ao passo que o segundo atuou como fator limitante à ocupação, visto que 70% da área da cidade está localizada na região de serras e picos ao norte do rio Paraíba do Sul e apenas 30%, na área de planalto, que é onde se concentra a maior parte da população (PMSJC, 1994).

A área urbana dessa cidade tem sofrido constantes ocupações inadequadas, criando desta maneira uma paisagem que contrasta visualmente com o desenvolvimento da cidade. Diante desse problema, a administração pública vem desenvolvendo projetos para legalizar as áreas em situações irregulares, com o objetivo de minimizar seus problemas habitacionais. Porém, não se sabe, até o momento, o grau de eficácia que estes alvos terão para sanar o problema habitacional existente.

Esse crescimento fez com que a propriedade da terra (concentração de renda) juntamente com custos de infra-estrutura, estimulassem o surgimento de loteamentos “clandestinos” criados sem obediência a legislação pertinente, muitas vezes considerada severa, em virtude da realidade brasileira (KURDJIAN & VALÉRIO FILHO, 2005).

Os loteamentos clandestinos ocorrem, no município de São José dos Campos, predominantemente nas regiões norte e leste do município (GOUVEIA, 2003; KURDJIAN & VALÉRIO FILHO, 2005). Segundo Costa (2001), a zona Leste de São José dos Campos possui cerca de 136.180 habitantes. No período de 1985 a 1987 a ocupação dessa região foi responsável por 44,1% do crescimento da área urbana do município. Ainda segundo a autora, no início da década de 1980, houve

na Zona Leste uma explosão de loteamentos, “legais” e “ilegais”, em decorrência da existência de grandes vazios urbanos nessa região e de outros motivos.

A região norte apresenta áreas com terrenos bastante acidentados, como morro e morrotes enquanto que a região leste é menos acidentada, apresentando um relevo de colinas médias e alongadas. As últimas oferecem maior liberdade de traçado à ocupação urbana (KURDJIAN & VALÉRIO FILHO, 2005). Desta forma, as duas áreas foram selecionadas levando em consideração as favelas já existentes (figura 7).

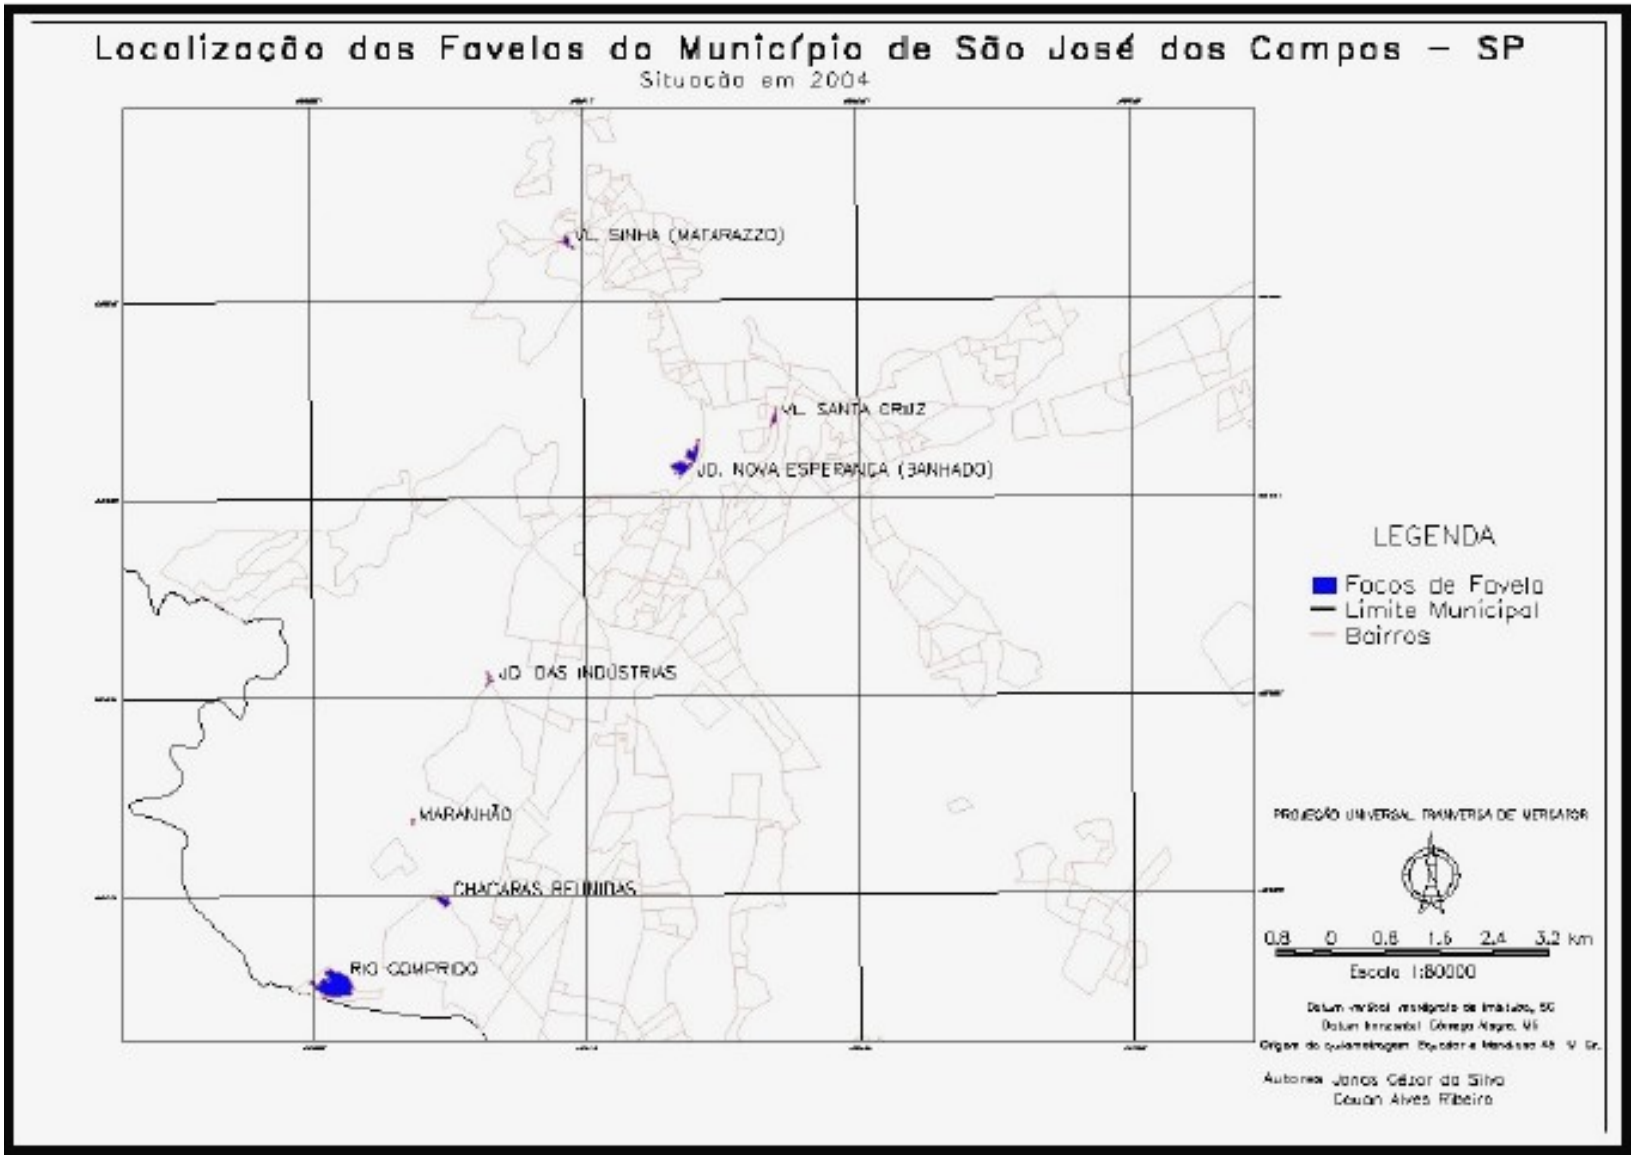
Localização das Favelas do Município de São José dos Campos – SP
Situação em 2004
VL. SINHA (MATARAZZO)
VL. SANTA CRUZ
JD. NOVA ESPERANÇA (BANHADO)
JD. DAS INDÚSTRIAS
MARANHÃO
CHÁCARAS REUNIDAS
RIO COMPRIDO
LEGENDA
Focos de Favela
Limite Municipal
Bairros
PROJEÇÃO UNIVERSAL TRANSVERSA DE MERCATOR
0,8 0 0,8 1,6 2,4 3,2 km
Escala 1:80000
Autores: Jonas Cezar da Silva
Cauan Alves Ribeiro

A cidade de São José dos Campos – SP foi escolhida para o estudo por apresentar uma ocupação acelerada e por possuir uma grande quantidade de favelas em áreas de ocupação irregulares.

3.2.3 Seleção de duas áreas

A seleção das duas áreas foi efetuada conforme trabalho de campo realizado *in loco,* de acordo com o mapa de localização das favelas na cidade de São José dos Campos e com as cenas que se dispunha do local. Foram então selecionadas 2 das maiores favelas de São José dos Campos, que juntas formam 26,5% das áreas ocupadas por favelas nesta cidade (SILVA et al, 2005). Estas duas áreas são significativas para testar a eficiência da metodologia a ser desenvolvida. A primeira área será usada para criar um método de classificação de cobertura da terra para áreas de favelas e a segunda para validar esse método.

A primeira área fica a sudeste e de acordo com o mapa de localização das favelas em São José dos Campos (figura 7), nela está localizada a favela Chácara Reunidas (13% da área total de favelas). A segunda área fica ao norte da cidade, e, de acordo com o mesmo mapa, está localizada nessa área a favela Nova Esperança (popularmente conhecida por Banhado). Para visualizar essas áreas ver figura 8.

Figura 8: Área teste: Favela Chácara Reunidas (à esquerda) e área de validação: favela Nova Esperança (direita).

Essas duas áreas representam favelas bem distintas. A primeira está mais próxima das favelas clássicas, com um amontoado de barracos, sem espaçamento entre eles e com ruas de traçado aleatório próximo a uma área comercial/industrial sem muita vegetação presente na área propriamente dita.

A outra está localizada ao lado de uma das áreas mais antigas e nobres de São José dos Campos, em uma área de declive, conhecida como região do Banhado, em meio à vegetação arbórea com um traçado de ruas e quadras próximas a cidade legal, apresentando além dos barracos, algumas casas de tamanho e estrutura consideráveis.

Foram analisadas duas áreas bem distintas, devido ao fato de serem as cenas das quais se dispunha.

3.2.4 Pré-processamento da imagem

Fusão das imagens

Para a realização da fusão entre bandas multiespectrais e pancromática, foi feita a reamostragem das bandas multiespectrais para 1 metro. As bandas multiespectrais - 2, 3 e 4 correspondentes ao Verde, Vermelho e infravermelho) foram reamostradas para 1 metro pelo método de vizinho mais próximo.

Logo após, foi efetuada a transformação IHS a partir da composição das três bandas multiespectrais. A fusão IHS (figura 9) foi feita no Software ENVI utilizando as bandas multiespectrais 2, 3, 4 e a pancromática. O Sistema de cores IHS representa as cores através de seus componentes básicos: intensidade (Intensity - I), matiz (Hue – H) e saturação (Saturation – S). A componente intensidade (I) fornece uma noção da resposta espectral do objeto e representa o brilho, o matiz (H) informa a cor predominante num determinado pixel da imagem e a saturação (S) estima a pureza da cor (MATHER, 1999).

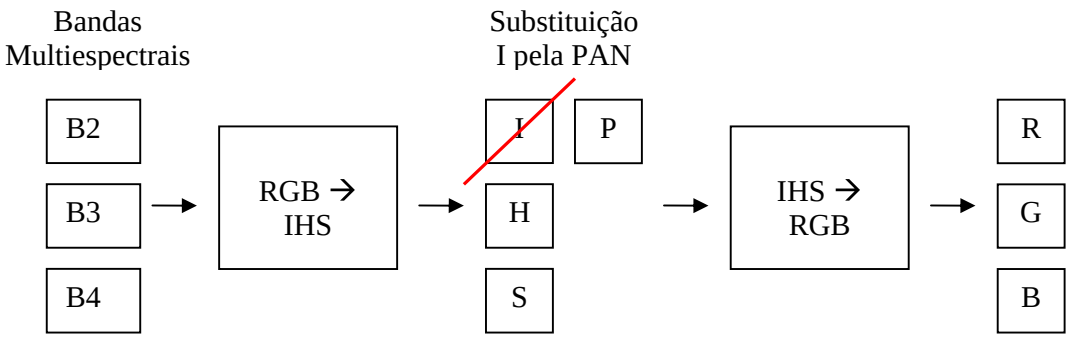

Figura 9: transformação IHS e fusão pelo método IHS de cores

Fonte: Adaptado de Fonseca, 2000.

A banda pancromática é, então, utilizada para substituir a componente I da imagem transformada e, em seguida, o método de transformação de cores IHS-RGB é executado. Com esse procedimento, a imagem resultante tem 1 metro de resolução espacial, e preserva as características espectrais, melhorando dessa maneira a visualização dos alvos de interesse, como telhados, ruas, arborização, entre outros. Este procedimento foi realizado para melhorar a visualização espacial da imagem numa composição colorida.

Índice de Vegetação Normalizado (NDVI)

Os índices de vegetação foram criados para tentar diminuir o trabalho de análises de dados orbitais, através da maximização de informações espectrais de vegetação no menor número de bandas de operação dos sensores (MOREIRA, 2003). Utilizar um índice de vegetação nesse trabalho teve por intuito ressaltar o comportamento espectral da vegetação em relação ao solo e a outros alvos da superfície terrestre, além de diferenciar tipos de vegetação. Esses índices resultam de transformações lineares da reflectância obtidas em duas ou mais bandas espectrais do espectro eletromagnético, através da soma, da razão entre bandas, da diferença, ou de qualquer outra combinação (WIEGAND et. al., 1991).

Na literatura são encontrados vários índices de vegetação, dentre eles os mais usados são: razão simples (RVI) e o Índice de Vegetação Diferença Normalizada (NDVI). Segundo Moreira (2003), os dois índices contêm o mesmo tipo de informações sobre parâmetros biofísicos das culturas, todavia o NDVI é mais

sensível à vegetação esparsa do que o RVI. Por esse motivo optou-se por usar o NDVI nesse trabalho para separar tipos de vegetação.

O NDVI é definido com base na resposta espectral da vegetação, que é alta nos comprimentos de onda do infra-vermelho próximo e baixa no vermelho. O índice é uma razão normalizada entre estas duas bandas (MATHER, 1999), como é mostrado na fórmula abaixo:

$$NDVI = \frac{IVP - V}{IVP + V} \qquad (12)$$

onde:
IVP - banda do Infravermelho próximo;
V - banda do vermelho.

Realizada a fusão e gerado o NDVI, foram selecionadas as áreas testes para efetuar a etapa de classificação da imagem orientada ao objeto.

3.2.5 Classificação da imagem

Essa etapa é dividida em quatro partes: definição das classes de cobertura do solo com base em interpretação visual das imagens IKONOS; segmentação por multiresolução, criação e inserção da rede hierárquica e classificação de cobertura da terra para áreas de favela.

Definição das Classes

Antes de fazer qualquer classificação é necessário saber quais feições de interesse serão extraídas na imagem. Assim para definir as classes de interesse, realizou-se uma interpretação baseada na imagem e nos segmentos

gerados (tabela 4). A imagem permitiu a observação das feições e a descrição das classes de interesse bem como o seu comportamento espectral. Os segmentos gerados serviram como base para observar forma e tamanho. Com isso, foram extraídos as classes de interesse e as áreas de treinamento para cada uma delas.

As classes de interesse para essa pesquisa foram baseadas nas classes elaboradas para área urbana em Pinho (2005). Os tipos de coberturas obtidas para uma área de favela, então, foram: vegetação arbórea, rasteira, cobertura de concreto/amianto, cobertura de cerâmica, solo exposto e sombra. Em razão das ruas serem de terra, não foi possível extrair essa classe, pois elas eram muito confundidas com solo exposto, já que em áreas de favela essa é uma classe comum. A interpretação propiciou ainda, gerar níveis de hierarquia que cada classe pertencia de acordo com seu significado dentro da rede.

Tabela 4: Resultado da interpretação nos domínios da imagem e segmentos.

Classes	Amostra na imagem	Cor (comp. 432)	Descrição das feições	Amostra nos segmentos	Descrição dos objetos
Vegetação arbórea		Verde escuro	Alta reflectância na banda do infravermelho; Textura rugosa com formas naturais; Localizada em toda imagem em meio a casas e ruas com padrão natural.		Objetos de tamanhos regulares, assimétricos e compactos.
Vegetação rasteira		Verde	Alta reflectância na banda do infravermelho; Textura áspera com formas definidas ou não		Objetos de tamanho médio, pouco fractados e assimétricos.
Telhado de cerâmica clara		Laranja	Alta reflectância em todas as bandas do visível; Em meio a ruas de terra e vegetações, tanto arbórea quanto rasteira, num contexto desarmonioso em relação a lotes, quadras e ruas.		Forma objetos retangulares ou quadrados na imagem, de tamanhos variáveis.
Telhado de cerâmica escura		Marrom avermelhado	Idem a cerâmica clara	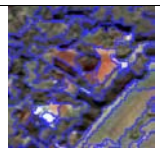	Semelhante a segmentos de cerâmica clara.
Telhado de concreto/amianto claro		Branco azulado	Alta reflectância nas bandas do azul; forma retangular definida		Semelhante a segmentos de telhado de cerâmica claro, diferindo-se somente por serem ainda mais simétricos que os telhados de cerâmica.
Telhado de concreto/amianto escuro		Cinza escuro a preto	Alta absorção nas bandas do visível;	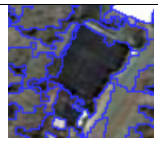	Segmentos grandes e pequenos dividem espaço nos segmentos para esta classe.
Solo exposto		Marrom claro	Alta reflectância nas bandas do visível; Textura lisa e forma irregular; De forma bastante irregular alguns são naturais outros de origem antrópica (“lotes”), aparecendo também nas ruas que não têm nenhum tipo de calçamento.	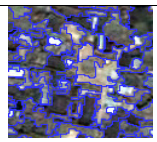	Bastante fragmentada, formada por vários segmentos de tamanhos variados desde formas alongadas até quadradas. Bastante assimétrico
Sombra		Preto	Baixa intensidade e alta absorção.	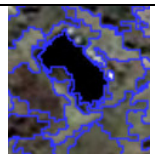	Forma assimétrica, em geral um segmento só na imagem forma uma sombra.

No eCognition essa informação é utilizada como nos classificadores convencionais, ao inserir-se uma classe da-se elementos amostrais desta classe para que haja uma associação por probabilidade. Porém, uma característica que o diferencia dos demais softwares de classificação de imagens são as regras de decisão fuzzy, que usam atributos que melhor distinguem cada classe na imagem. Esses atributos são escolhidos de acordo com a descrição das classes na tabela 4, e por meio de testes.

Para discriminar cada classe no eCognition pode-se então utilizar a ferramenta visão do atributo (feature view) que visualiza em forma de imagem, os atributos do objeto, do relacionamento entre classes e do relacionamento global do objeto. Essa ferramenta permite que o usuário interaja no processo, pois é usado o conhecimento adquirido no processo de interpretação visual de imagens, para determinar qual atributo separa melhor cada objeto que pertence a determinada classe.

Quando as classes são difíceis de serem separadas como, por exemplo**,** solo exposto e telhado cerâmico, então é utilizada a ferramenta editor de amostras (sample editor), que a partir de amostras coletadas na imagem para cada uma das duas classes que se deseja separar, indica a função e a freqüência que melhor separa as duas classes, podendo ou não gerar a função automaticamente, dependendo da escolha do usuário (Figura 10).

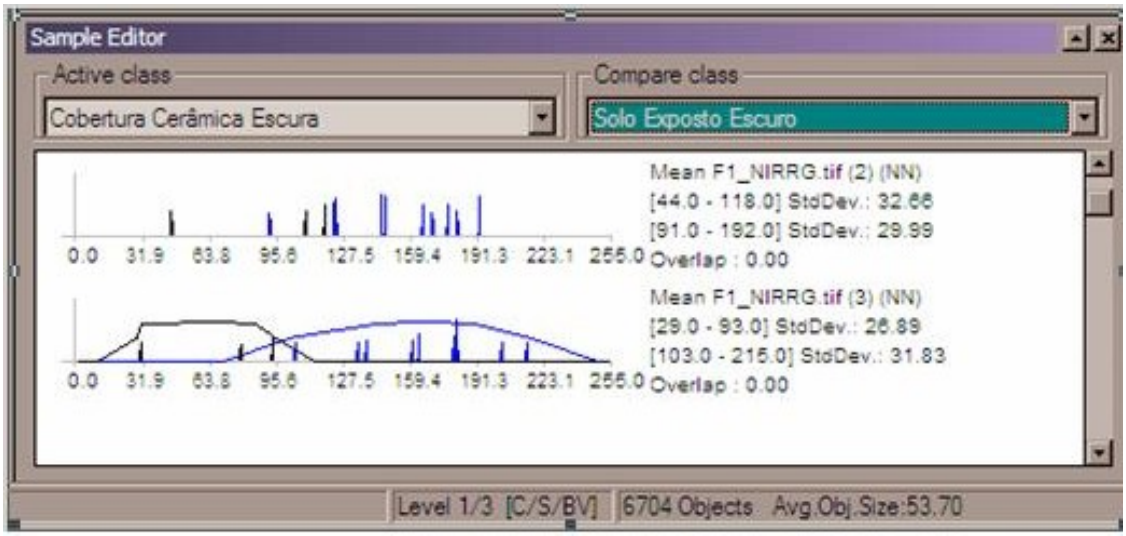

Figura 10: Histograma comparando as funções de solo exposto e telhado cerâmico no atributo média espectral na banda do vermelho.

Estabelecidas as classes partiu-se para o processo de segmentação da imagem.

Segmentação

A segmentação foi utilizada para dividir a imagem em partes que possuem alta correlação com os objetos reais. O método empregado na pesquisa foi a segmentação por multiresolução baseado nas características espaciais e espectrais. Num primeiro momento, ocorreu a escolha dos parâmetros de segmentação: grau de homogeneidade de forma e cor que permitem um agrupamento de objetos conforme uma resolução mais detalhada possível. Usando segmentações repetidas ou re-segmentações, mais parâmetros poderão ser inseridos, construindo, assim, relações entre os objetos em diferentes níveis (WILLHAUCK, 2000). Esses parâmetros a serem inseridos são informações exteriores como vetores de quadras, cartas temáticas entre outros.

Durante a segmentação multiresolução, foram respondidas as 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 o fator de escala, de forma e de compacidade de acordo com os objetos que se desejava separar na imagem. Ao realizar este processo de segmentação no software eCognition, é 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. O processo procura a minimização da heterogeneidade, levando em conta a dimensão do objeto.

A soma ponderada de cor e forma gera o critério similaridade f que é dado por (DEFINIENS, 2004):

$$f = w * h_{cor} + \left(1 - w * h_{forma}\right) \tag{5}$$

onde,

w - peso atribuído a cor no processo de segmentação variando de 0 a1;

h_{cor} - heterogeneidade de cor;

h_{forma} - heterogeneidade 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 e1 (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 heterogeneidade para cor é dada por:

$$h_{cor} = \sum_{c} w_c * \left(n_{união} * \sigma_c^{união} - \left(n_{obj1} * \sigma_c^{obj1} + n_{obj2} * \sigma_c^{obj2} \right) \right) \quad (1)$$

Onde,

w_c - peso atribuído a cada banda multiespectral;

$n_{união}$ - número de pixels do possível objeto a ser formado;

$\sigma_c^{união}$ - desvio padrão do possível objeto a ser formado;

n_{obj1} - número de pixels do objeto 1;

σ_c^{obj1} - desvio padrão do objeto 1 para cada banda c;

n_{obj2} - número de pixels do objeto 2;

σ_c^{obj2} - desvio padrão do objeto 2 para cada banda c.

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

$$h_{forma} = w_{comp} * h_{comp} + \left(1 - w_{comp}\right) h_{suav} \quad (4)$$

onde,

w_{comp} - peso atribuído a compacidade variando de 0 a 1;

h_{comp} - heterogeneidade para compacidade;

h_{suav} - heterogeneidade para a suavidade.

Compacidade é a razão entre o perímetro de um objeto pela raiz quadrada do número de pixels.

A notação de heterogeneidade para compacidade é dada por:

$$h_{comp} = n_{união} * \frac{l_{união}}{\sqrt{n_{união}}} - \left(n_{obj1} * \frac{l_{obj1}}{\sqrt{n_{obj1}}} + n_{obj1} * \frac{l_{obj2}}{\sqrt{n_{obj2}}} \right) \quad (2)$$

Onde,

l - perímetro do objeto;

n - tamanho do objeto em números de pixels.

$\frac{l_{união}}{\sqrt{n_{união}}}$ - compacidade do possível objeto a ser formado;

$\frac{l_{obj1}}{\sqrt{n_{obj1}}}$ - compacidade do objeto 1 para cada banda;

$\frac{l_{obj2}}{\sqrt{n_{obj2}}}$ - compacidade do objeto 2 para cada banda.

A suavidade é a razão entre o perímetro do objeto e o perímetro do bounding box, ou seja, do retângulo envolvente as bordas da imagem com menor comprimento possível. E é expresso por:

$$h_{suav} = n_{união} * \frac{l_{união}}{b_{união}} - \left(n_{obj1} * \frac{l_{obj1}}{b_{obj1}} + n_{obj1} * \frac{l_{obj2}}{b_{obj2}} \right) \quad (3)$$

Onde,

l - perímetro do objeto;

n - tamanho do objeto em números de pixels;

b - perímetro do bounding box;

$\frac{l_{união}}{b_{união}}$ - suavidade do possível objeto a ser formado;

$\frac{l_{obj1}}{b_{obj1}}$ - suavidade do objeto 1 para cada banda;

$\frac{l_{obj2}}{b_{obj2}}$ - suavidade do objeto 2 para cada banda.

Segundo HOFMANN (2001), para a segmentação de áreas urbanas é recomendada uma estratégia de segmentação bottom-up, com a geração de pequenos objetos no nível base, ou seja, no nível mais baixo de segmentação e em grandes segmentos no nível mais alto. Nos níveis intermediários permanecem as informações necessárias para separar alvos que nestes dois níveis somente, grosseiro e fino, não são possíveis.

Com base nas classes de interesse tiveram início às tentativas de segmentação, para encontrar os melhores valores dos parâmetros exigidos nesse processo, bem como para extrair os objetos de interesse na imagem. Mas como a segmentação era por multiresolução foi necessário ter níveis de segmentação, pois apenas um nível perderia a hierarquia por herança e por grupos, o que tornaria o processo de segmentação e classificação muito difícil. Por esse motivo, depois de vários testes, foram estabelecidos três níveis de segmentação

Esses níveis geraram uma segmentação que foi do nível mais fino ao nível mais grosseiro. No nível mais fino tentou-se separar o máximo de feições da imagem, com uma grande quantidade de detalhes. Para encontrar o melhor fator de escala para este nível foi estabelecida uma amostragem de 10 objetos significativos na imagem. Foram realizados vários testes para estabelecer o parâmetro que melhor separasse os 10 objetos na cena. Já no nível médio tentou-se separar a

área da vegetação do resto e no nível mais grosseiro as quadras e não-quadras. Para encontrar o fator de escala nesse caso se usou os super-objetos dos 10 objetos da amostragem do nível 1. Essa segmentação teve por objetivo separar as áreas de favela do restante, até chegar no nível onde os objetos extraídos na imagem eram as classes de cobertura da terra para favelas. Nesse nível o fator de escala foi um valor grande o suficiente para separar razoavelmente os contornos das favelas das demais áreas da melhor maneira possível. Na tabela 5 são encontrados os valores utilizados em cada nível.

TABELA 5: Parâmetros da Segmentação

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

Além desses valores, foram utilizados pesos iguais nas imagens para a segmentação e também layer temático, contendo quadras e ruas, importado do software Envi. Na segmentação do nível 2, foi utilizado somente a imagem NDVI pois o objetivo desse nível era separar vegetação do que não era vegetação.

Após a segmentação houve a avaliação visual das imagens segmentadas para analisar o seu desempenho de acordo com o que desejava extrair e o que foi extraído. Nessa avaliação buscou-se ainda, feições do terreno que ficaram divididas em um ou mais objetos, a fim de fundi-los e melhorar, com isso, a segmentação. Como exemplo, foram feitas fusões de algumas feições na vegetação.

A avaliação da segmentação foi efetuada visualmente, pois segundo Definiens (2004), uma fonte forte e experiente para avaliação de técnicas de segmentação é o olho humano.

Formulação da rede hierárquica

Nessa etapa, a rede hierárquica foi gerada a partir das chaves de interpretação (tabela 4). Bishr (1997), salienta que o contexto é expresso através de definições semânticas dos objetos e de suas estruturas descritivas.

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, obtém-se uma segmentação, em níveis hierárquicos, que traz informações sobre o que significa cada objeto dentro de cada escala do nível hierárquico. Esse método gera uma rede semântica onde as relações entre os objetos podem ser expressas através de relações de atributos do objeto. Ligações permitem restringir valores de atributos a um determinado objeto. As relações semânticas são descritas como: **parte de** uma classe ou **tipo de** uma classe ou **é** da classe **X,** e se propagam verticalmente**,** enquanto as relações entre os atributos se propagam horizontalmente (ANTUNES, 2003).

A rede foi testada em dois experimentos, um para testá-la e outro para validá-la, objetivando garantir a eficiência na aplicação a uma terceira área, isto é, se a rede funcionar para duas áreas diferentes de favelas, poderá ser utilizada para outras áreas com pouca ou nenhuma modificação.

Classificação

A classificação tem por objetivo 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). Nesta pesquisa foi utilizada a Classificação Multiespectral de Imagem orientada a objeto mediante regras fuzzy, que teve como finalidade substituir a análise visual dos dados por técnicas quantitativas de análise automática, visando a identificação dos elementos presentes na cena. A classificação consiste no processo que conecta as classes em uma hierarquia de classes para determinada cena de acordo com o que se deseja classificar na mesma.

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 sua busca na definição de classes de cobertura a partir da segmentação feita anteriormente e das classes previamente definidas com seus respectivos atributos. Os objetos na imagem segmentada tornam-se elementos da imagem a serem classificados.

Durante o processo de classificação, cada objeto é indicado a uma dada classe e conecta-se a 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.

O operador define a base de regras da rede hierárquica, para avaliar os graus de pertinência de cada segmento das classes estabelecidas. (MANSOR et al., 2002). Para inserir esse conhecimento dos objetos, dois fatores devem ser

levados em consideração neste processo: quais atributos serão utilizados para diferenciar cada classe e qual tipo de regra de decisão será adotada para cada classe.

São muitas as espécies de atributos que o *eCognition* disponibiliza (tabela 6). O programa apresenta vários recursos que auxiliam na construção das funções para separar cada classe, baseados em atributos do objeto, de relacionamento das classes, relacionamento Global e operadores lógicos.

De acordo com Definiens (2004), os atributos do objeto se subdividem em vários outros, tais como: espectrais, textura, forma, hierarquia e temático. Os atributos espectrais fornecem informações dos valores espectrais das bandas e do relacionamento com atributos espectrais de vizinhança. Os de forma se subdividem em valores de área, perímetro, largura, grau de simetria, densidade e direção principal. Os de textura são baseados nos valores espectrais dos *pixel*s contidos no objeto, exemplos de textura são a matriz de co-ocorrência de níveis de cinza e média do tamanho dos subobjetos. Os atributos de hierarquia trazem informação de posicionamento do objeto no nível hierárquico, como por exemplo: o nível que 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 atributos de relacionamento são utilizados para relacionar funções a partir da associação com outros objetos da rede. Os relacionamentos globais recorrem a parâmetros estatísticos para a cena ou para uma classe.

Tabela 6: Tipos de atributos disponíveis no programa *eCognition*

Grupos de atributos	Sub-grupo	Atributos
Atributos de objetos	Espectrais	Média, desvio padrão, relação $\frac{banda\, l_1}{\sum l}$, níveis de brilho
	Forma	Tamanho, comprimento, relação área/perímetro,índice de forma, assimetria, densidade
	Textura	Matriz de co-ocorrência, haralick ou baseada nos subobjetos (média do tamanho dos subobjetos)
	Hierarquia	Indica o posicionamento no nível hierárquico
	Temáticos	Tipos de uso do solo ou de vegetação
Atributos relacionados a classes	Relação com objetos vizinhos	Distância de um objeto em relação a outro de uma determinada classe
	Relação com subobjetos	Área total dos subobjetos de uma determinada classe
	Relação com super-objetos	Existência de uma classe especifica de super-objetos
	Pertence a	Valor da pertinência do objeto a uma classe
	Classificado como	Classe para qual um objeto foi classificado
	Valor de classificação de	Valor do grau pertinência para uma classe especifica
Atributos Globais	Relacionados com a cena global	Média total de uma determinada banda
	Relacionados com uma classe global	Área total de todos os objetos de uma determinada classe em todos os níveis
	Similaridade de uma determinada classe	Define que a descrição de uma classe é idêntica a de uma outra determinada classe

Fonte: Definiens, 2004

Os operadores lógicos são utilizados para relacionar funções que descrevam valores de atributos que os definem. A forma das funções determina o grau que o objeto pertencerá a uma determinada classe. O conjunto de operadores disponíveis permite a construção de regras de decisão, como junção de diferentes atributos dos objetos. A caracterização das classes necessita inicialmente, de uma combinação de expressões que possibilitam a construção de uma gramática de

classificação, denominada na ligação de regras de decisão *fuzzy*, por operadores *fuzzy*.

Os operadores lógicos disponíveis são (DEFINIENS, 2004):

And (min): $A \cap B = m(\mu A; \mu B)$.

And (*): o valor de pertinência à classe é igual ao produto dos valores de pertinência.

Or (max): $A \cup B = \max(\mu A; \mu B)$.

Mean (arithm): o valor de pertinência à classe é igual à média aritmética dos valores.

Mean (geo): o valor de pertinência à classe é igual à média geométrica dos valores.

Quando se trabalha com regras de decisão pode-se utilizar combinações desses operadores, porém, lembrando que a complexidade da classificação será aumentada.

De acordo com Encarnação et al (2005), o comportamento dos objetos num dado atributo é concedido por uma função que determina a forma do intervalo de pertinência. O *eCognition* apresenta na figura 11, as seguintes funções para a descrição de uma classe:

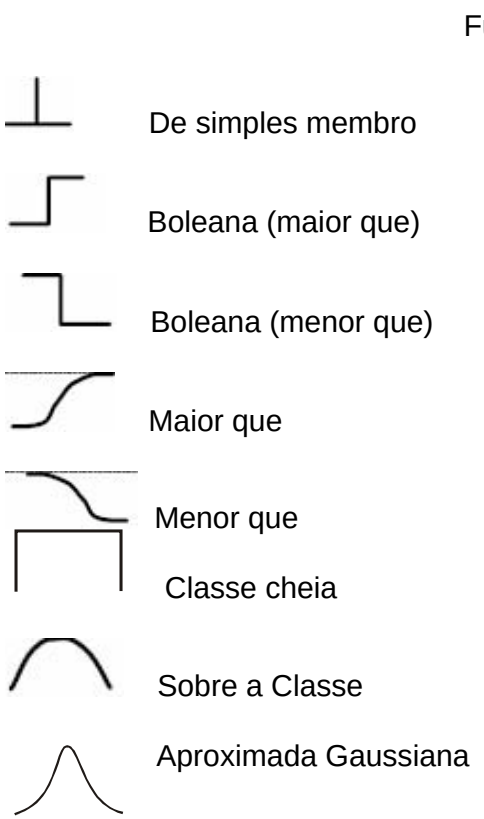

Figura 11: Principais tipos de funções de pertinência *fuzzy*.
Fonte: adaptado de Encarnação et al (2005)

Segundo Encarnação et al (2005), a função de pertinência de um objeto a uma determinada classe é dada por: i) escolha do operador lógico, ii) da função, e iii) atributos que descrevem os objetos.

Assim, os parâmetros para cada classe têm que ser delimitados, conforme o exemplo na figura 12, onde há a discriminação desses itens para separação de duas classes – terra e água, onde o atributo para terra é negar a existência de água:

Classe	Operador lógico	Atributo	Função	Intervalo do atributo
Terra	And (min)	Negação de água	----	----
Água	And (min)	Media da banda IVP		(12 - 22)
		ICF		(0,4 – 0,89)

Figura 12: Formação da função *fuzzy*: um exemplo para classe água e terra.

Fonte: Encarnação et al, 2004.

A formulação de regras fuzzy, apoiadas nesses diferentes descritores dos objetos, permite a realização da semântica dos objetos ou regiões, conseqüentemente, possibilita uma classificação interativa e próxima à realidade (QUINT, 1997).

O eCognition foi o software utilizado para esse tipo de classificação.

Neste programa, um dado objeto é classificado baseado na função de pertinência que lhe foi definida dentro da rede hierárquica a qual ele pertencia. A rede pré-estabelecida é colocada na rotina de classificação do programa. As funções receberam valores limites baseados nos histogramas do(s) atributo(s) que foram selecionados para formar a função de pertinência para cada classe. Esses valores limites são estabelecidos por meio de testes que auxiliam na determinação do melhor intervalo do atributo estabelecido para cada classe. Para concluir o processo gera-se a imagem classificada de cobertura da terra para as áreas de favelas.

4.2 Avaliação da Classificação

Foi realizada uma avaliação temática através de trabalho de campo que teve por finalidade comparar a classificação semi-automática com a verdade terrestre. Mas para analisar estatisticamente a confiabilidade dos dados foram utilizados a Matriz de Confusão ou Erro e o coeficiente de concordância Kappa. As unidades amostrais tomadas como verdade terrestre foram áreas delimitadas na imagem por meio de verificação *in loco* selecionadas aleatoriamente de forma a ter uma mesma porcentagem de representação de áreas para cada classe. Foi realizada uma amostragem aleatória devido a complexidade da área.

Após a seleção da amostragem de erro se calcula a matriz de confusão ou erro que serve para analisar os erros e acertos no resultado da classificação. Com base na mesma amostragem foi calculado o índice de concordância Kappa que fornece a concordância entre a classificação e os dados de referência. Com isso, foi verificada a viabilidade de uso da análise orientada a objeto desenvolvida em mapeamentos de favelas em imagens IKONOS II.

A instabilidade no processo de escolha das funções fuzzy para cada classe foi encontrada por meio do grau de instabilidade de acordo com o item 2.6.2.

4. RESULTADOS

Neste capítulo são apresentados os resultados para as duas áreas de favelas, bem como discutidas as redes hierárquicas construídas e por fim, é mencionado o processo de segmentação e classificação que levou aos resultados aqui apresentados.

4.1 Rede Hierárquica

A classificação das imagens foi realizada nos três níveis de segmentação. No nível superior - 3 (figura 13) foram separadas as classes quadras e não quadras, sendo que a classe não quadras foi subdividida nas classes ruas e áreas não projetadas. Nesse nível as quadras serviram como restrição para separar áreas legais das favelas. No nível 2, o objetivo foi separar vegetação de não-vegetação. A rede nesse nível pode ser melhor observada na figura 14. A rede hierárquica do nível inferior - 1 é um pouco mais complexa. Nesse sentido, torna-se imprescindível descrevê-la aqui, já que foram necessários realizar muitos testes para chegar a fase final da rede para o nível 1 (figura 15), devido aos vários materiais que se encontram nas classes de cobertura da terra, principalmente em áreas de favela, onde as casas são em sua maioria improvisadas. A junção dos três níveis gerou a rede que foi inserida no eCognition. Esta rede foi testada para o experimento 1 e validada no experimento 2.

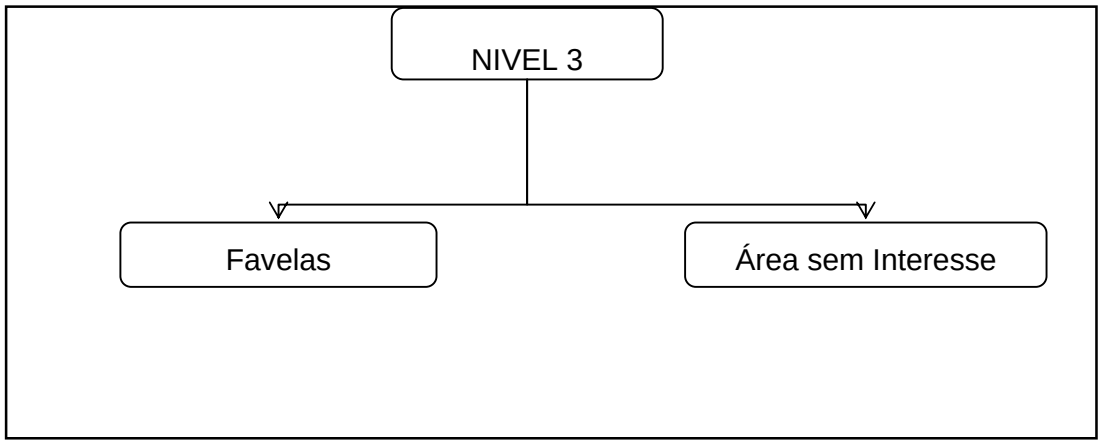

Figura 13: Rede Hierárquica para o nível 3

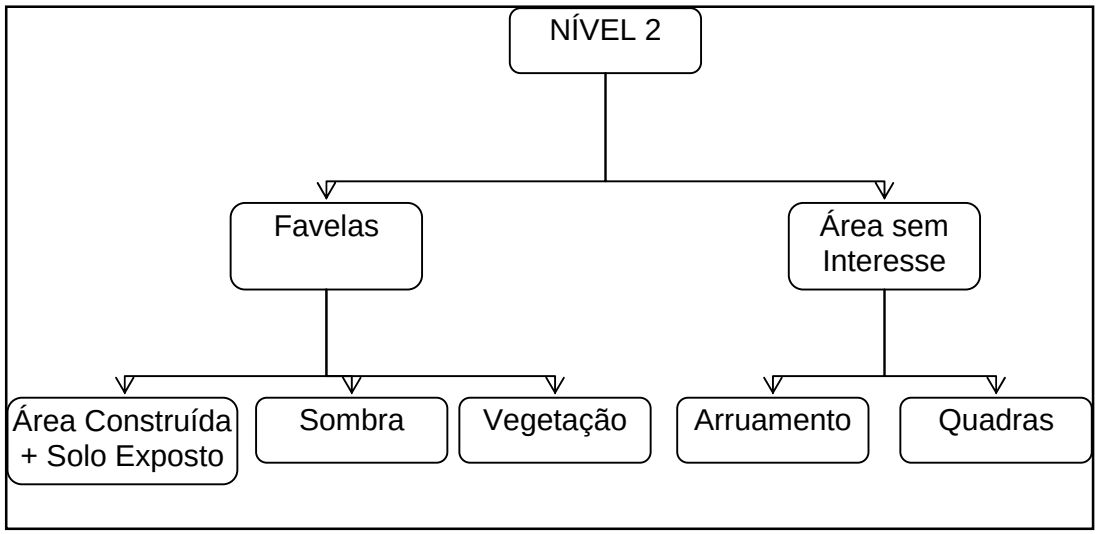

Figura 14: Rede Hierárquica para o nível 2.

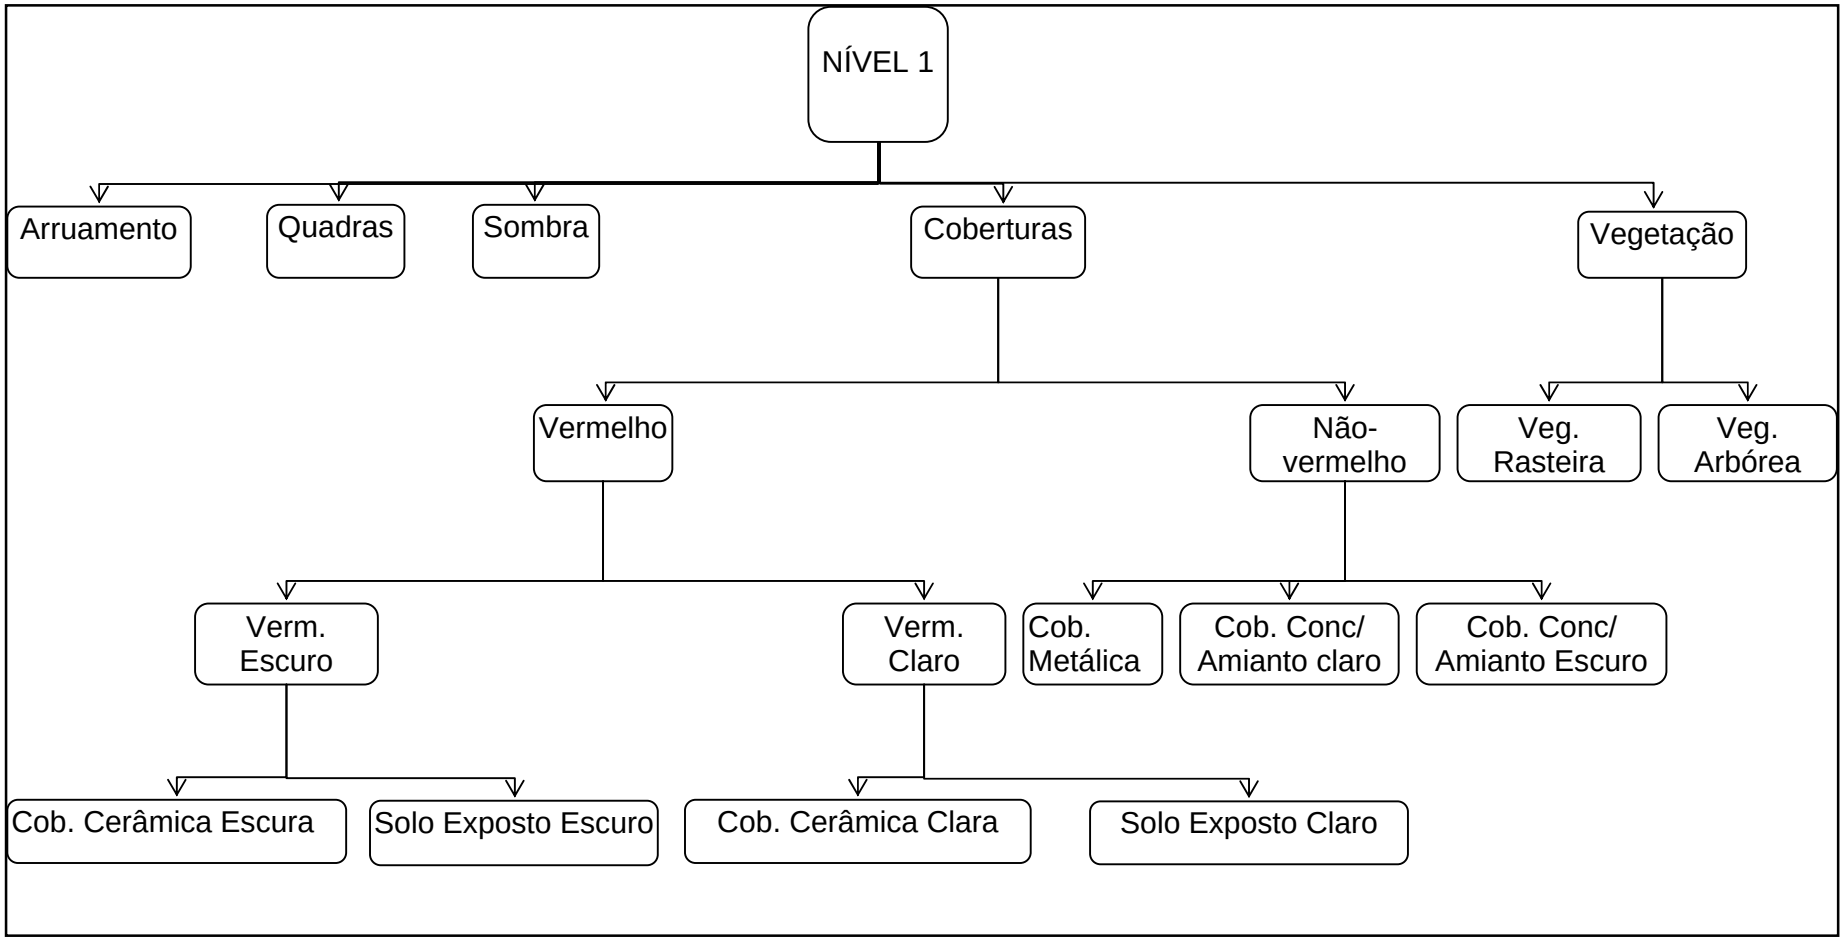

Figura 15: Rede Hierárquica por herança para o nível 1.

Concebida a rede hierárquica para classificar cobertura de áreas de favelas, ela é inserida mantendo os níveis a que cada classe pertence no eCognition. É nesse momento que se determina a hierarquia de cada classe dentro do nível a que pertence como mostrado no esboço teórico citado nas figuras 13,14 e 15 e atribui as funções de pertinência para cada classe (figura 16).

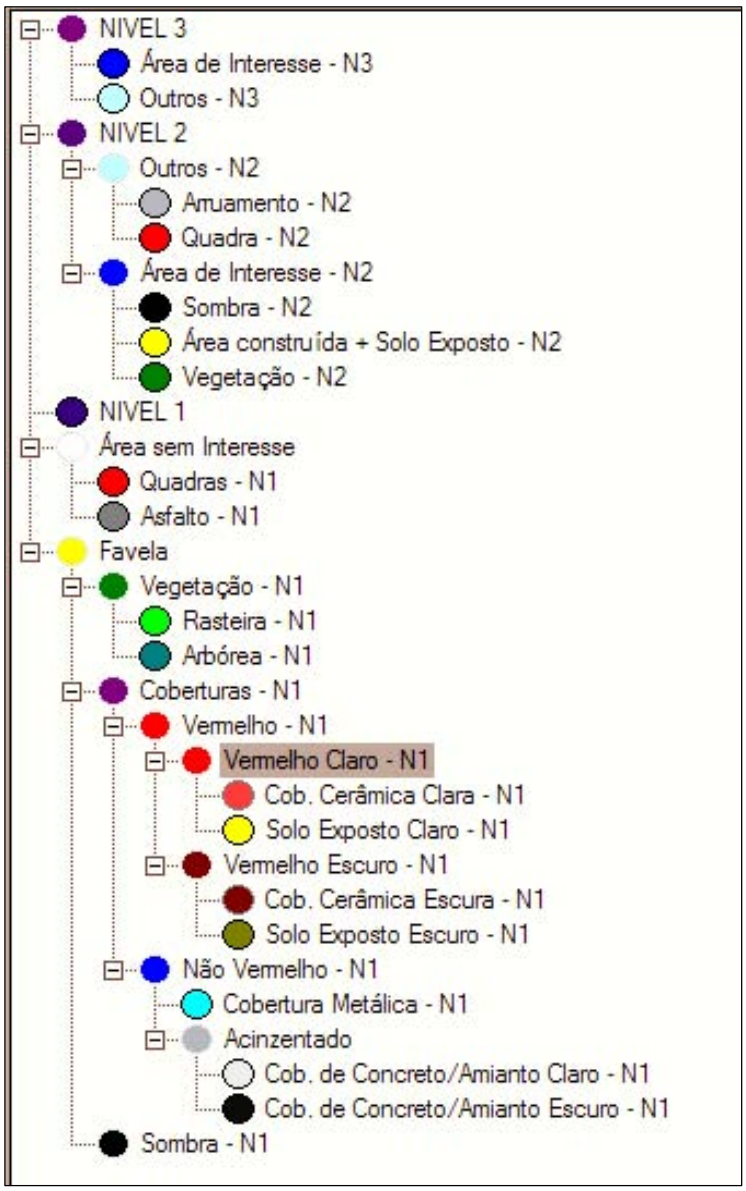

Figura 16: Rede hierárquica para classificar cobertura de favelas no eCognition.

Assim, para cada classe foi gerada uma função fuzzy que a distinguia das demais. Para uma melhor interpretação, na tabela 7 estão descritos as semânticas de cada objeto para cada nível hierárquico, bem como quais descritores e funções foram usados para formar as funções de pertinência no processo de regra de decisão para a classificação. Os descritores foram estabelecidos por meio de testes baseados nos conhecimentos geográfico e espectral de cada classe. Deste modo, dentre uma variada gama de descritores, selecionou-se aqueles que deram melhores resultados para distinguir as classes de cobertura de áreas faveladas. Selecionado o descritor foi possível analisar qual função cumpriria melhor desempenho junto a esse descritor. Com isso gerou as funções de pertinência fuzzy por meio da associação de uma determinada função com um ou mais descritores.

Tabela 7: Relação da rede hierárquica entre objetos e descritores

Classes				**Função**	**Descritores**
Nível 3 – Super-objetos					
Área de Favelas – N3					Média da Banda 2
Área sem interesse – N3					Negação de 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

4.2 Apresentação e Avaliação dos Resultados

Nesta seção são apresentados, avaliados e comparados os resultados da aplicação do nível 1 para a área teste (Favela Chácara Reunidas) e para área de validação (Favela Nova Esperança). A aplicação do mesmo método para as duas áreas tem por fim validá-lo.

Para a validação do método foi comparada a coerência na aplicação da mesma rede hierárquica, a exatidão temática das duas classificações (por meio da matriz de confusão) e finalmente foi avaliado o desempenho do processo de classificação por meio do grau de instabilidade, que é apresentado por classes.

4.2.1 Experimento 1: Área teste → Favela Chácara Reunidas

O experimento 1, foi aplicado a uma cena Ikonos II de São José dos Campos que continha a Favela denominada de Chácara Reunidas. O método de classificação orientado ao objeto, foi executado no programa eCognition.

O objetivo consistiu em analisar a aplicabilidade desta abordagem orientada a objetos no processo de classificação de imagens de alta resolução. Para isso foi proposto um método de classificação para áreas de favelas (ver capitulo 3), que constou de 3 redes hierárquicas que organizaram as classes semanticamente, afim de auxiliar no processo de classificação. Uma vez elaborada a rede hierárquica, ela foi acoplada a rotina de classificação do software.

Dessa maneira a estrutura das imagens no processo de segmentação e classificação pode ser visualizada na figura 17.

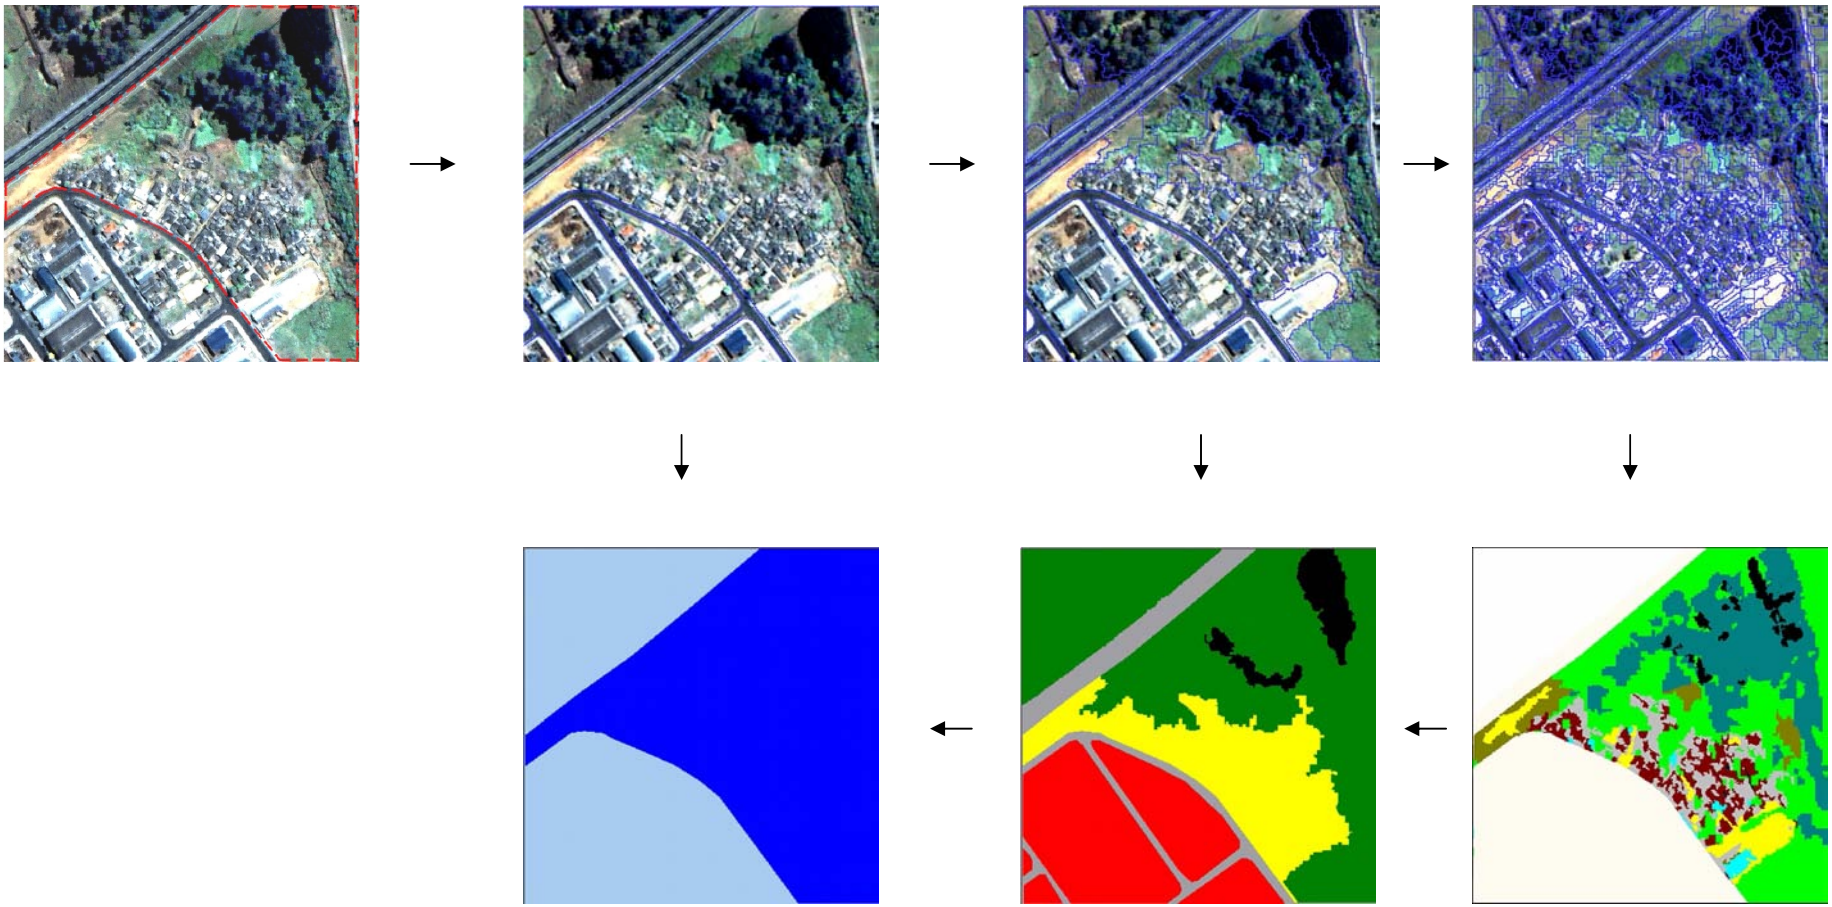

Figura 17: Estrutura da segmentação multiresolutiva e classificação para áreas de favelas

No nível 3 foram extraídos feições grandes que permitiram a distinção de áreas de favelas do restante da cena (figura 18).

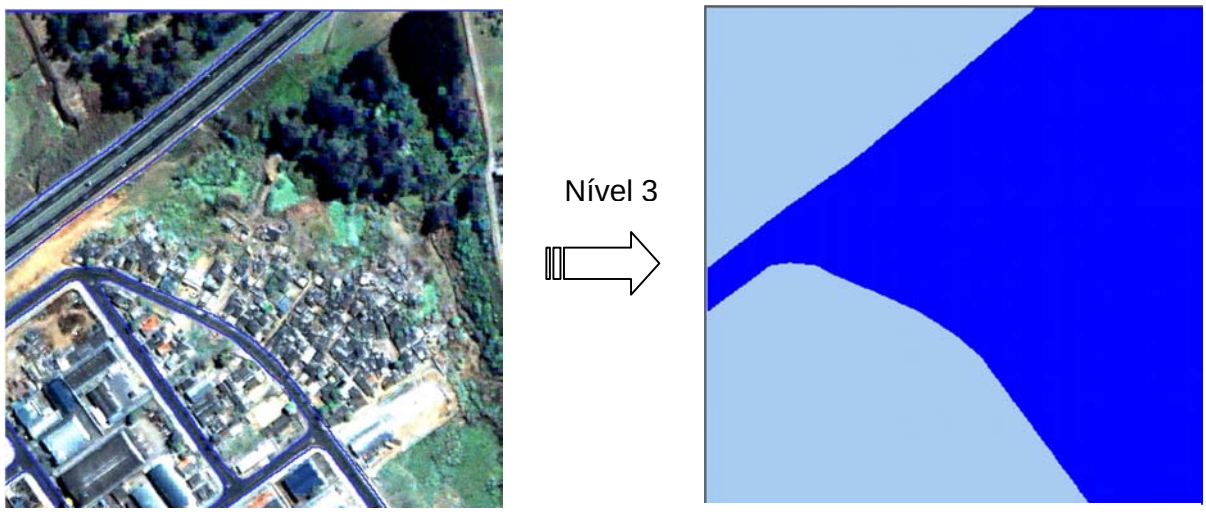

Escala → 1:1000; Cor → 0,1;
Forma → 0,9; Compacidade → 0,5;
Suavidade → 0,5.

Classificação: Quadras (azul claro) e áreas não-planejadas(azul escuro)

Figura 18: Segmentação e classificação para o nível 3

No nível dois o intuito foi fazer uma segmentação que separassem super-objetos na cena, a fim de classificar vegetação de não-vegetação. Sendo que a área que não continha vegetação foi dividida em quadras, arruamento e sombra (figura 19)

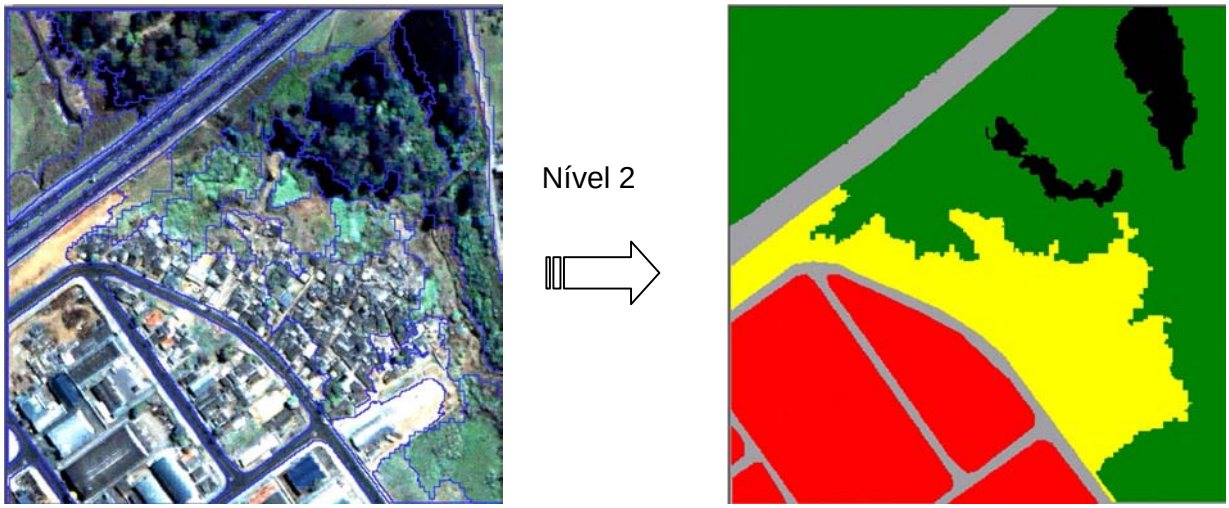

Escala → 1:50; Cor → 0,7;
Forma → 0,3; Compacidade → 0,5;
Suavidade → 0,5.

Classificação: vegetação e Não-vegetação

Figura 19: Segmentação e classificação para o nível 2

No nível 1 a segmentação foi realizada para separar as feições de cobertura do alvo pois nesse nível se queria classificar os tipos de cobertura da terra para áreas de favela (figura 20).

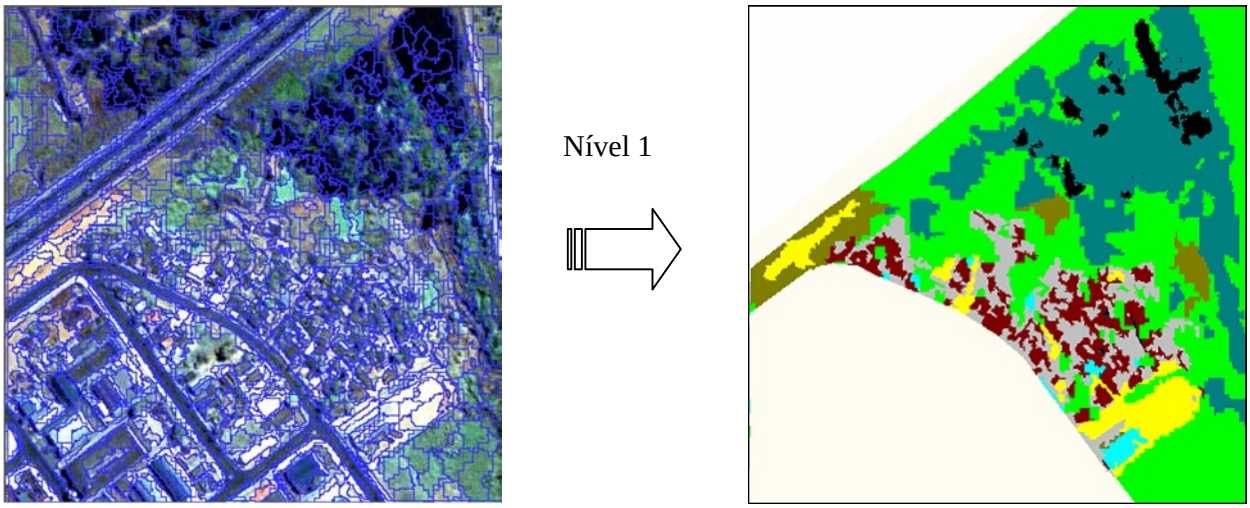

Escala → 1:15; Cor → 0,7;
Forma → 0,3; Compacidade → 0,5;
Suavidade → 0,5.

Classificação: tipos de coberturas

Figura 20: Segmentação e classificação para o nível 1

O resultado da classificação para a favela Chácara Reunidas pode ser visualizado na figura 21.

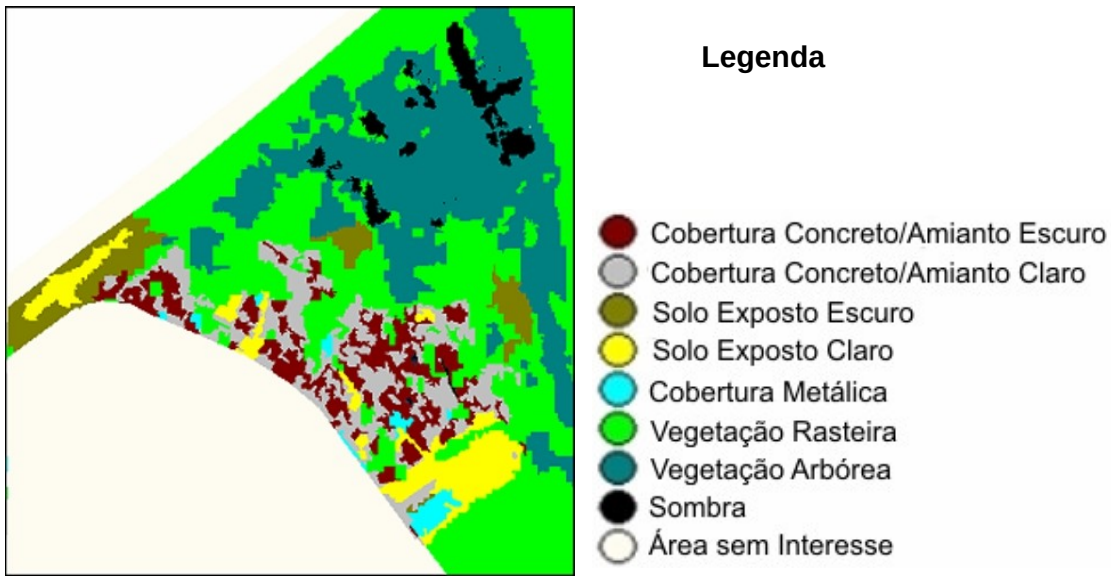

Figura 21: Classificação de Cobertura da Terra para Favela Chácara Reunidas

Visualmente é possível observar que o resultado da classificação foi satisfatório, discriminando bem as classes de interesse na imagem com poucos erros no processo de classificação, como está apresentado na tabela 8. Quando esses erros foram percebidos visualmente, ainda durante o processo eles foram corrigidos com a ferramenta de classificação manual.

Tabela 8: Matriz de Confusão e Coeficiente Kappa para a Favela Chácara Reunidas

Referência / Classificacão	Concreto /Amianto Escuro	Concreto /Amianto Claro	Solo Exposto Escuro	Solo Exposto Claro	Cob. Metálica	Vegetação Rasteira	Vegetação Arbórea	Sombra	**Total**
Concreto/Amianto Escuro	**9**	0	0	0	0	0	0	0	**9**
Concreto/Amianto Claro	0	**7**	0	0	0	0	0	0	**7**
Solo Exposto Escuro	0	0	**11**	2	0	0	0	0	**13**
Solo Exposto Claro	0	0	0	**7**	0	0	0	0	**7**
Cobertura Metálica	0	0	0	0	**6**	0	0	0	**6**
Vegetação Rasteira	1	1	3	0	0	**21**	1	1	**28**
Vegetação Arbórea	0	0	0	0	0	0	**22**	1	**23**
Sombra	0	0	0	0	0	0	0	**5**	**5**
Não Classificado	1	4	5	0	2	0	0	**2**	**14**
Total	**11**	**12**	**19**	**9**	**8**	**21**	**23**	**9**	**112**
Produtor	0,818	0,583	0,579	0,778	0,75	1	0,957	0,556	----------
Usuário	1	1	0,846	1	1	0,75	0,957	1	----------
Índice Kappa	**0,752**								
Exatidão Total	**0,786**								

Ao analisar a matriz de erro verifica-se que os resultados foram satisfatórios. Porém as classes, cobertura de concreto/amianto claro, solo exposto escuro e sombra tiveram os piores resultados com a exatidão do produtor, ficando abaixo de 60% classificado corretamente. Este valor também mostra o erro de omissão, onde nota-se que esse erro ficou em torno dos 40 %.

Um importante agravante foram os poucos elementos amostrais tomados para algumas das classes, tais como: cobertura metálica e solo exposto claro, devido também a pouca ocorrência das mesmas.

A acurácia obteve uma índice considerado bom (satisfatório) que ficou próximo aos 79% de acurácia total. O índice Kappa de acordo com a tabela 2, foi considerado muito bom para esta classificação ficando no intervalo entre 60 e 80%. No gráfico 1, observa-se a distribuição dos resultados do índice Kappa para cada classe no processo de classificação do experimento 1.

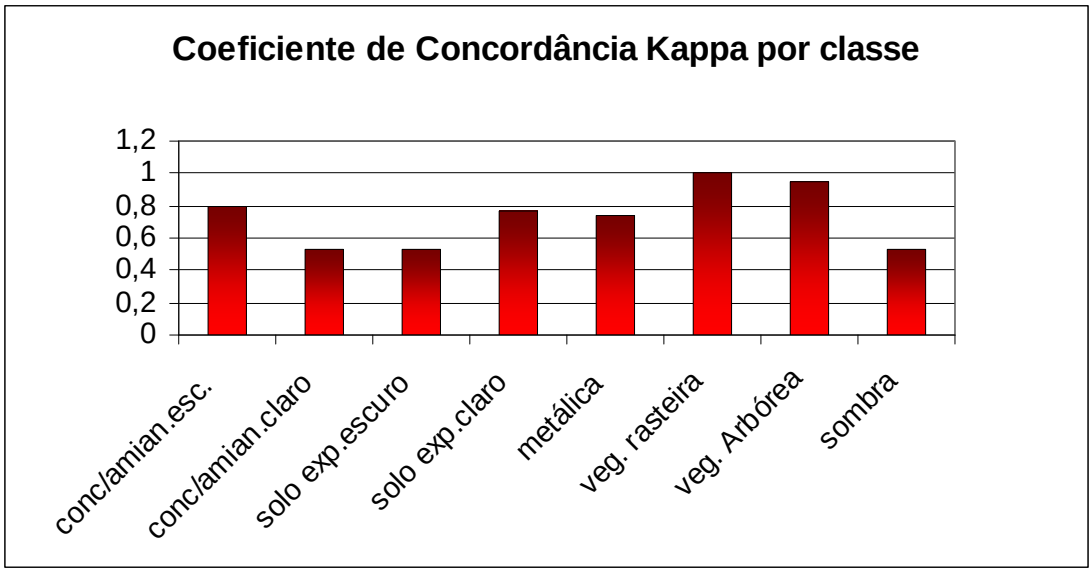

Gráfico 1: Coeficiente de Concordância Kappa para cada Classe do Experimento 1

Pode-se dizer que não existem grandes discrepâncias nas classes analisadas, pois de acordo com a tabela 2 nenhum dos resultados da classificação

ficou fora do que se considera um bom resultado, ou seja, nenhuma classe ficou abaixo dos 40 %. Porém, houve certa confusão nas classes concreto/amianto claro, solo exposto escuro e sombra. Da classe concreto/amianto claro 30% dos pixels não foram classificados. O solo exposto escuro, 46% dos pixels foram incluídos nas classes vegetação rasteira e não classificados. Já a classe sombra devido a sua localização, em geral, próximas a áreas vegetadas, sofreu forte influência da mesma, o que causou quase 45% de erro na classificação desta classe. Esta confusão fica bem clara quando se analisa o índice Kappa para cada classe, pois as três classes também apresentaram os piores índices 0,556, 0,524 e 0,535, respectivamente.

Utilizou-se, também, o índice de ambigüidade apresentado no item 2.6.2. levando em consideração que a proximidade entre graus de pertinência pode gerar alguma hesitação na associação de um objeto à determinada classe. Quanto mais próximo de zero o índice de ambigüidade (Ia) for, menor certeza é observada.

A Tabela 9 apresenta a relação entre ambigüidade e coeficiente de concordância Kappa.

Tabela 9: Grau de ambigüidade comparada com o índice de concordância kappa por classe para a classificação da favela Chácara Reunidas

CLASSE	1ª > PERTINÊNCIA	2ª > PERTINÊNCIA	I_A	AMBIGUIDADE	Kappa
Cobertura Cerâmica Escura	----------	----------	----------	----------	----------
Cobertura Cerâmica Clara	----------	----------	----------	----------	----------
Cobertura Concreto/Amianto Escuro	0,736	0,366	0,503	Boa	0,802
Cobertura Concreto/Amianto Claro	0,728	0,292	0,599	Boa	0,556
Cobertura Metálica	0,886	0,543	0,387	Aceitável	0,736
Sombra	1	0,754	0,246	Ambígua	0,535
Solo Exposto Escuro	0,923	0,429	0,535	Boa	0,524
Solo Exposto Claro	1	0,674	0,326	Aceitável	0,736
Vegetação Arbórea	0,753	0,358	0,525	Boa	0,945
Vegetação Rasteira	0,842	0,124	0,853	Muito boa	1

Esses índices de ambigüidades aferiram apenas o quão dúbio 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 cometido um erro ao optar pelo maior grau de pertinência como critério de associação.

Ao analisar o processo de classificação quanto ao grau de ambigüidade, considera-se no geral, um bom desempenho 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.

Mas analisando de uma maneira geral isso pode ter ocorrido, como já foi até mencionado em relação ao Kappa, pela interferência dos alvos que geraram as sombras. Nessa área, as sombras foram geradas, principalmente, por árvores altas. 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 não deixa dúvidas que foi um bom processo de classificação, com bons resultados, próximos aos resultados obtidos pelo índice de concordância das classes.

Dessa maneira, a avaliação por meio do grau de ambigüidade e do índice de concordância entre o que foi classificado e o que realmente existia no local analisado, trouxe a comprovação da aplicabilidade do método de classificação orientada a objeto disponível no software 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 um desempenho satisfatório.

4.2.2 Experimento 2: Área de validação → Favela Nova Esperança (Banhado)

Para esta área foi aplicado o mesmo método utilizado no experimento 1, a fim de testar a validade do método para outra área de favela, apenas modificando alguns dos intervalos das funções, já que se quer um método que possa ser utilizado para outras áreas de mesma característica com menores mudanças possíveis seja na rede hierárquica, nos atributos ou nas funções fuzzy formadas por eles.

Deste modo, a estrutura de segmentação e classificação ficou da seguinte forma (Figura 22).

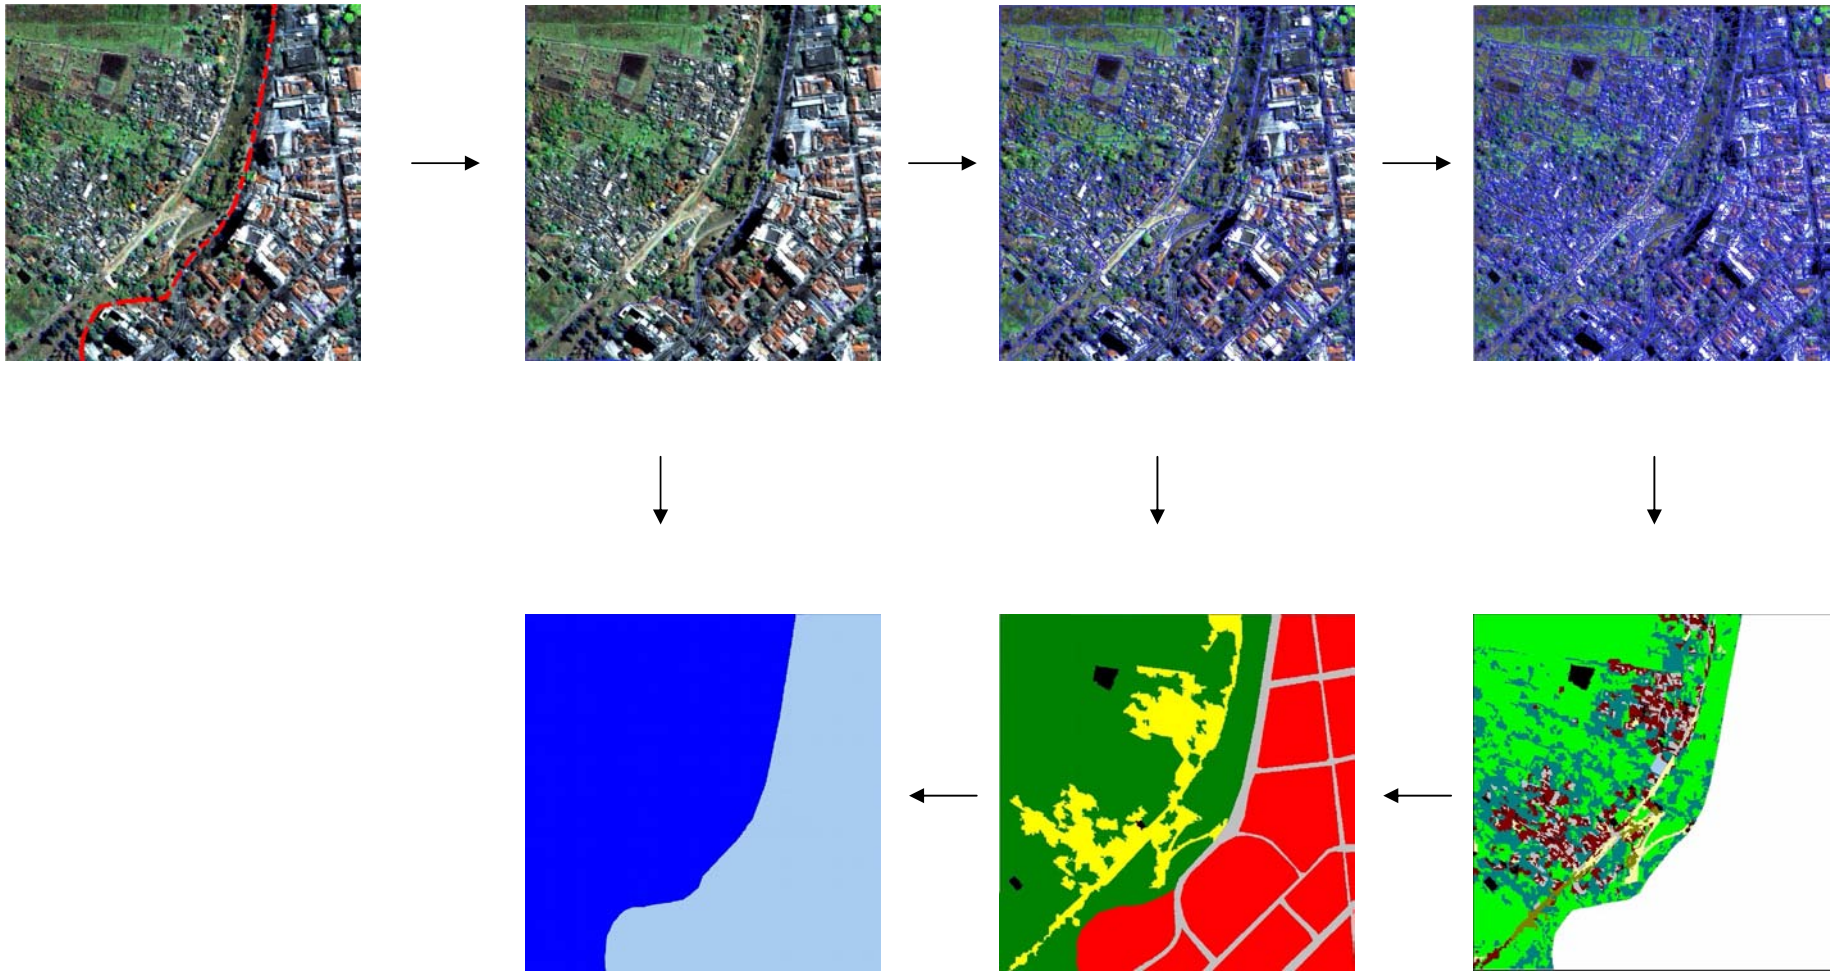

FIGURA 22: Estrutura de segmentação e classificação para a favela Nova Esperança (Banhado)

Da mesma forma que para o experimento 1, foram elaboradas as segmentações e classificações. Como estão apresentadas nas figuras 23, 24 e 25.

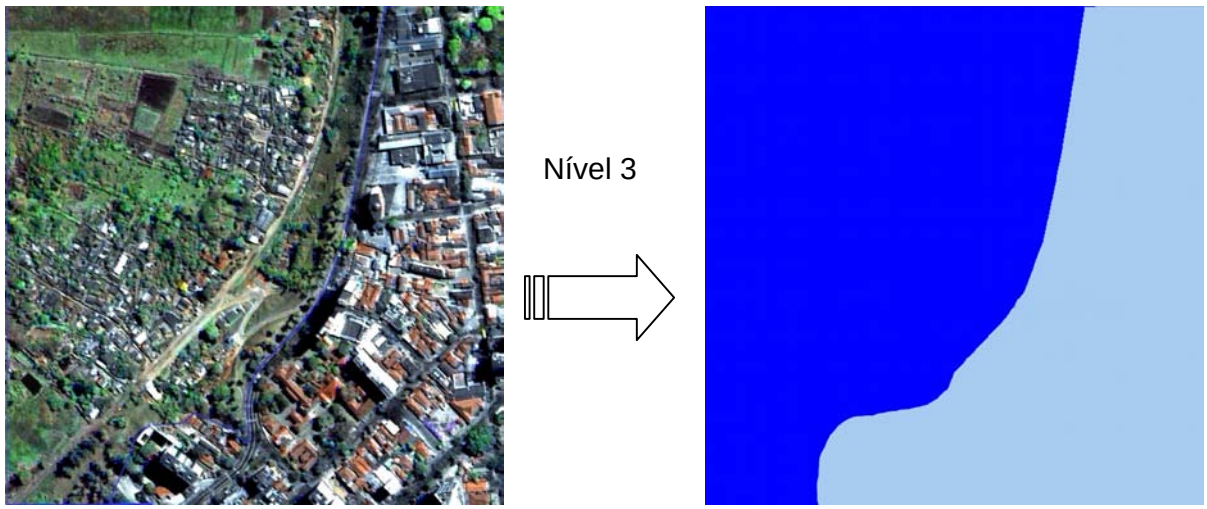

Escala → 1:1000; Cor → 0,1;
Forma → 0,9; Compacidade → 0,5;
Suavidade → 0,5.

Classificação: Quadras e áreas não-planejadas

Figura 23: segmentação e classificação para o nível 3

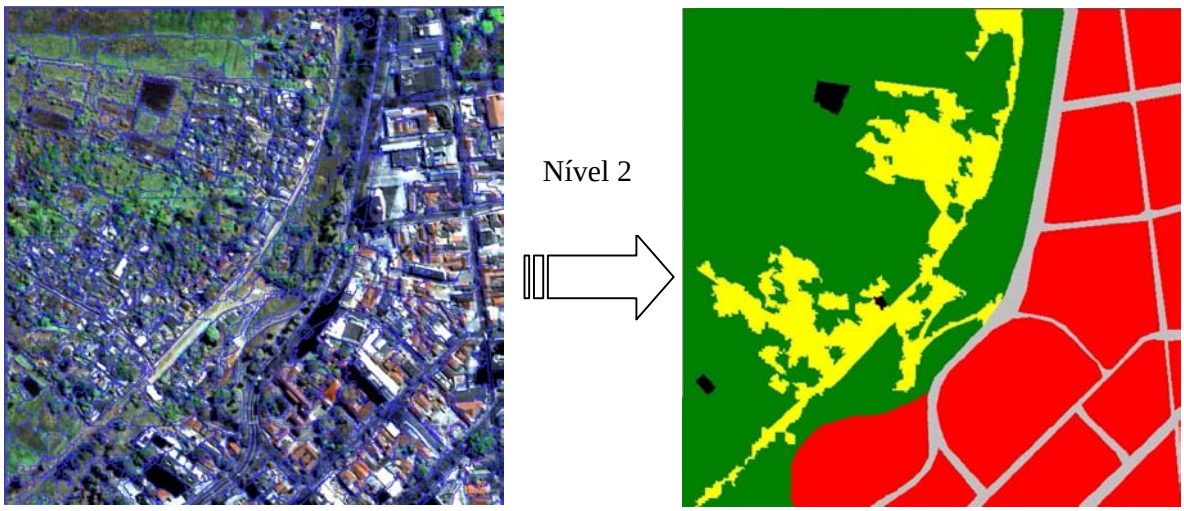

Escala → 1:50; Cor → 0,7;
Forma → 0,3; Compacidade → 0,5;
Suavidade → 0,5.

Classificação: vegetação e Não-vegetação

Figura 24: Segmentação e classificação para o nível 2

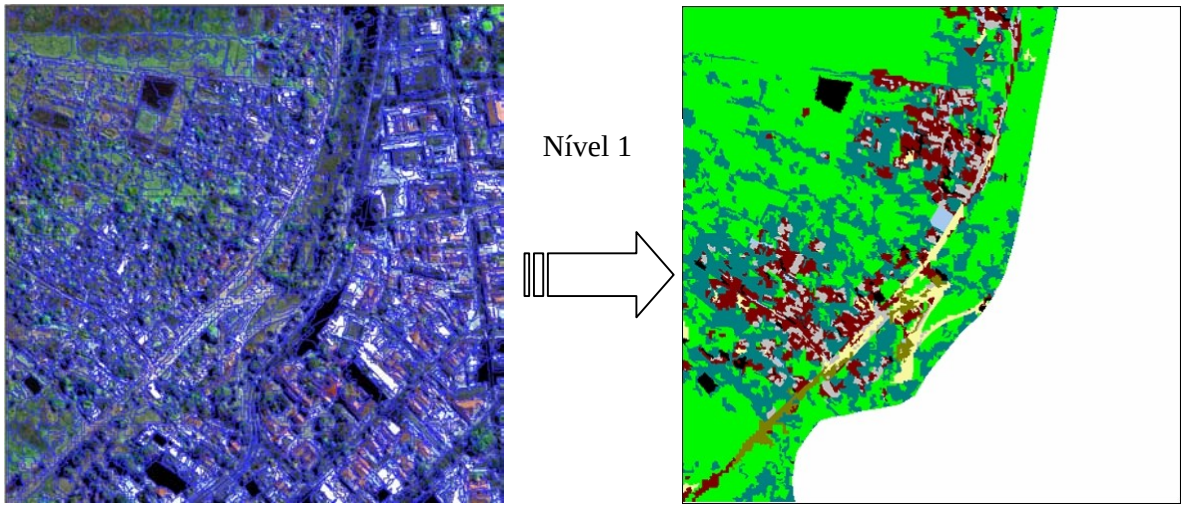

Escala → 1:15; Cor → 0,7;
Forma → 0,3; Compacidade → 0,5;
Suavidade → 0,5.

Classificação: Tipos de coberturas

Figura 25: Segmentação e classificação para o nível 1

O resultado obtido por meio dessa estrutura pode ser visto na figura 26 e a matriz de confusão está apresentada na tabela 10.

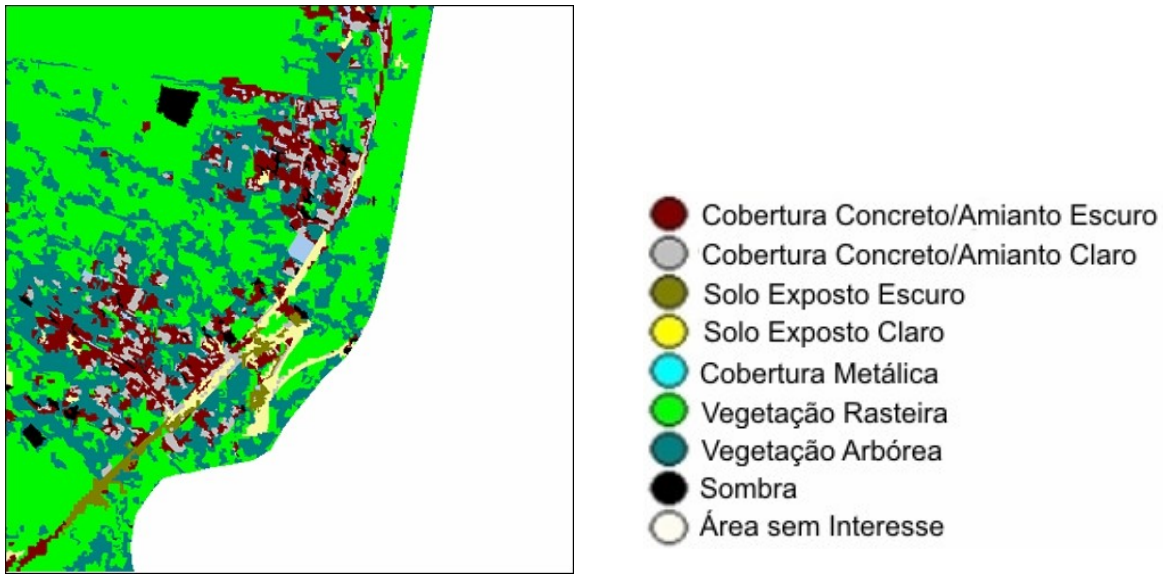

Figura 26: Classificação de Cobertura da Terra para a Favela Nova Esperança

Essa área era um pouco distinta da primeira, mas mesmo assim apresentou um bom resultado para a 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.

Para maior confiabilidade nessas análises, serão considerados e comparados os valores de matriz de confusão encontrados na classificação do experimento 1 com a do experimento 2. Bem como o *Kappa* encontrado e sua exatidão global.

Tabela10: Matriz de confusão e coeficiente Kappa para a área da favela Nova Esperança

Referência / Classificacão	Sombra	Concreto /Amianto Claro	Concreto /Amianto Escuro	Metálica	Solo Exposto Claro	Solo Exposto Escuro	Vegetação Arbórea	Vegetação Rasteira	**Total**
Sombra	**8**	0	0	2	0	0	0	0	**10**
Concreto/Amianto Claro	0	**9**	5	0	3	2	0	0	**19**
Concreto/Amianto Escuro	0	0	**9**	8	0	1	0	0	**18**
Cobertura Metálica	0	0	0	**9**	0	0	0	0	**9**
Solo Exposto Claro	0	0	0	0	**9**	7	0	0	**16**
Solo Exposto Escuro	0	0	0	0	0	**12**	0	0	**12**
Vegetação Arbórea	0	0	0	0	0	0	**6**	0	**6**
Vegetação Rasteira	0	0	0	0	0	3	7	**10**	**20**
Não Classificado	0	0	0	1	0	0	0	**0**	**1**
Total	**8**	**9**	**14**	**20**	**12**	**25**	**13**	**10**	**111**
Produtor	1	1	0,643	0,45	0,75	0,48	0,462	1	----------
Usuário	0,8	0,474	0,5	1	0,563	1	1	0,5	----------
Índice Kappa	**0,602**								
Exatidão Total	**0,649**								

Da mesma forma para o experimento 1, o gráfico 2 apresenta uma comparação do índice de concordância kappa para cada classe.

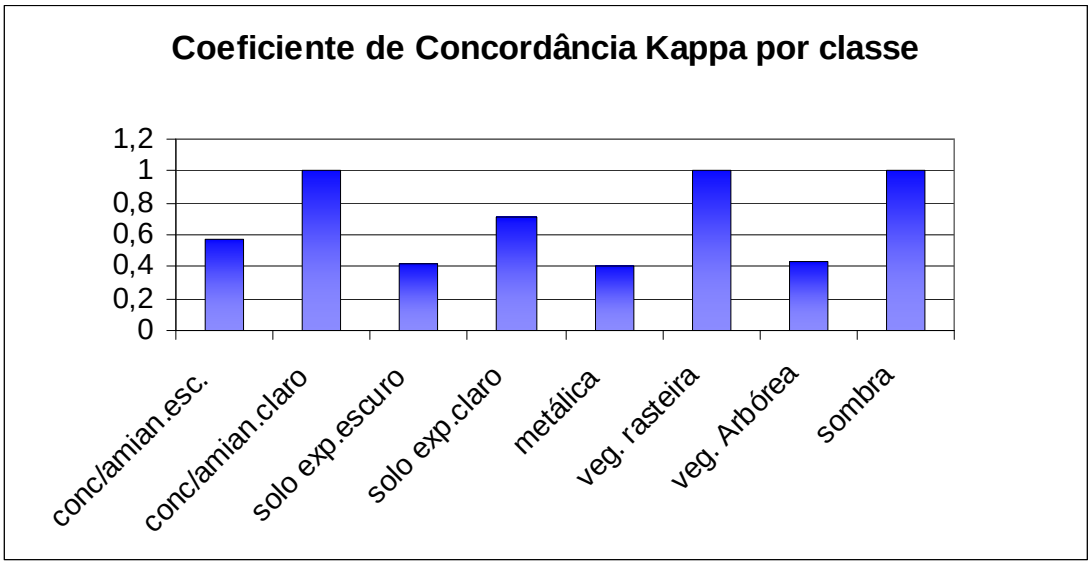

Gráfico 2: Coeficiente de Concordância *Kappa* para cada classe do Experimento 2

Nota-se uma maior irregularidade no comportamento dos dados. Aqui houveram três classes que ficaram com índices de concordância próximos do mínimo que se espera para serem consideradas como bem classificadas de acordo com a tabela 2. A classe concreto/amianto escuro tem um índice bom, porém seu desempenho ainda não foi próximo ao do primeiro experimento. Sendo assim, as quatro classes, com valores baixos foram as responsáveis pela queda de desempenho da classificação para o experimento 2. Mesmo com essa queda, os resultados do coeficiente *kappa* para a classificação foram satisfatórios, não interferindo na acurácia total da classificação.

As acurácias do produtor e do usuário para algumas classes ficaram abaixo do esperado, o que indica que houve um bom número de erros de omissão

ou comissão no processo classificação, ou seja, ora se incluiu um objeto numa classe a qual ele não pertencia, ora se excluiu da qual ele pertencia.

Tanto o Coeficiente de concordância *kappa*, como a exatidão global para essa classificação tiveram boas percentagens. A acurácia total da classificação foi de quase 65%, enquanto que o coeficiente *kappa* passou, de acordo com a tabela 2, para uma classificação muito boa no intervalo de 60 a 80%.

Para avaliar a estabilidade do processo de classificação também foram calculadas as ambigüidades existentes no mesmo, por meio do índice de instabilidade proposto no item 2.6.2. A tabela 11 apresenta os graus de pertinência 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.

Tabela 11: Índice de Ambigüidade e Kappa para cada classe para a classificação da favela Nova Esperança

CLASSE	1ª > PERTINÊNCIA	2ª > PERTINÊNCIA	I_A	AMBIGUIDADE	Kappa
Cobertura Cerâmica Escura	----------	----------	----------	----------	----------
Cobertura Cerâmica Clara	----------	----------	----------	----------	----------
Cobertura Concreto/Amianto Escuro	1	0,759	0,241	Ambígua	0,574
Cobertura Concreto/Amianto Claro	0,754	0,245	0,675	Boa	1
Cobertura Metálica	0,693	0,395	0,430	Aceitável	0,401
Sombra	0,432	0,328	0,241	Ambígua	1
Solo Exposto Escuro	0,835	0,333	0,601	Boa	0,708
Solo Exposto Claro	1	0,500	0,500	Aceitável	0,417
Vegetação Arbórea	0,826	0,358	0,567	Boa	0,431
Vegetação Rasteira	0,935	0,308	0,671	Boa	1

Aqui, 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 ao analisar que dentre as oito classes obtidas pelo processo de classificação, duas são ambíguas, 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 ambigüidade não há grandes problemas em considerar essa classificação, pois mesmo nas classes ambíguas, a classe concreto/amianto escuro tem pertinência 1, ou seja, dificilmente ela foi associada erroneamente, O que remete a apenas uma classe no processo que realmente implica incerteza na classificação (classe sombra). Assim sendo, esse resultado não prejudica a análise, podendo ser consideradas as funções fuzzy adotadas como satisfatórias para separar e classificar os alvos com um bom grau de confiabilidade. Para comparar os resultados foram elaborados gráficos, que permitiram uma comparação do desempenho do coeficiente kappa para cada uma das classes envolvidas nos dois experimentos, e, também, observar a acurácia obtida por meio da exatidão do produtor e do usuário, (gráficos 3 a 5).

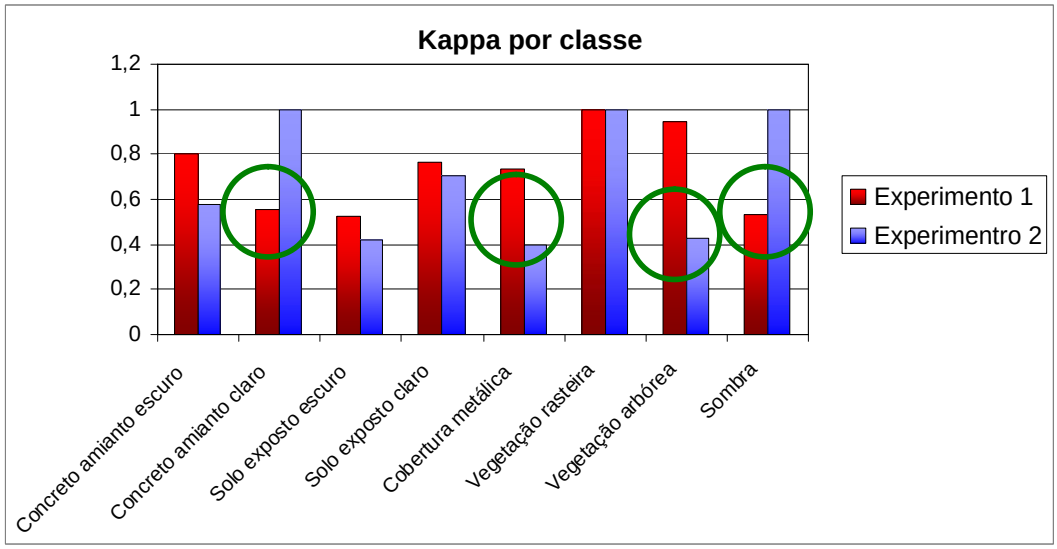

Gráfico 3: Comparação do coeficiente de concordância kappa por classe nos dois experimentos

As classes com maiores discrepâncias foram destacadas por círculos para facilitar a visualização. Essas classes concreto/amianto claro e sombra tiveram melhor desempenho no segundo experimento, fato este justificável pela pouca existência de alvos das mesmas no primeiro experimento. Assim, com poucas amostras qualquer erro gerado representa uma porcentagem maior de erros ocorrendo também nos outros dois casos. A classe cobertura metálica ocorre mais no primeiro experimento que no segundo. As árvores no primeiro experimento são mais frondosas e mais separadas, gerando menos confusão com os demais alvos enquanto no segundo, são facilmente confundidas devido ao local de declive resultando muita sombra, o que provoca muitas vezes a inclusão de vegetação rasteira nesta classe.

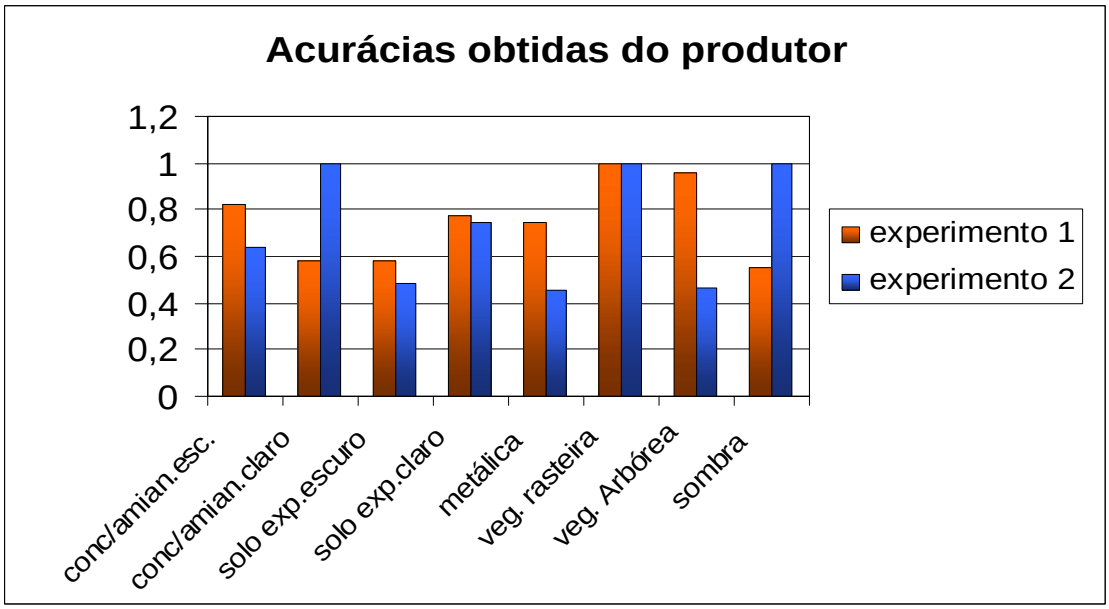

Gráfico 4: Comparação da acurácia do Produtor.

De acordo com o gráfico 4, nota-se que há uma regularidade na curva dos resultados que representa o experimento 1, demonstrando uma classificação mais homogênea com erros melhores distribuídos e resultados finais mais satisfatórios. No experimento 2 isso não ocorre, pois há classes com alta acurácia (concreto amianto claro, vegetação rasteira e sombra com 100% de acurácia) e outras próximas ao limite do que se considera ruim numa classificação (cobertura metálica – 45% e vegetação arbórea – 46,2 % de acurácias, respectivamente). Nota-se que essa discrepância é gerada por haver um grande número de erros de omissão nas últimas classes mencionadas. Havendo essa oscilação, notada por meio do gráfico, explica-se o motivo de algumas classes deste segundo experimento terem obtido resultados satisfatórios, mas a acurácia total da classificação ser inferior ao resultado do primeiro experimento.

Assim, no primeiro experimento os erros de omissão estão distribuídos em todas as classes, gerando melhores resultados. Já no segundo, os erros estão concentrados em poucas classes. Neste caso, pode-se considerar que,

as baixas acurácias, para algumas classes apenas diminui a acurácia do resultado final da classificação, mas não a inviabiliza.

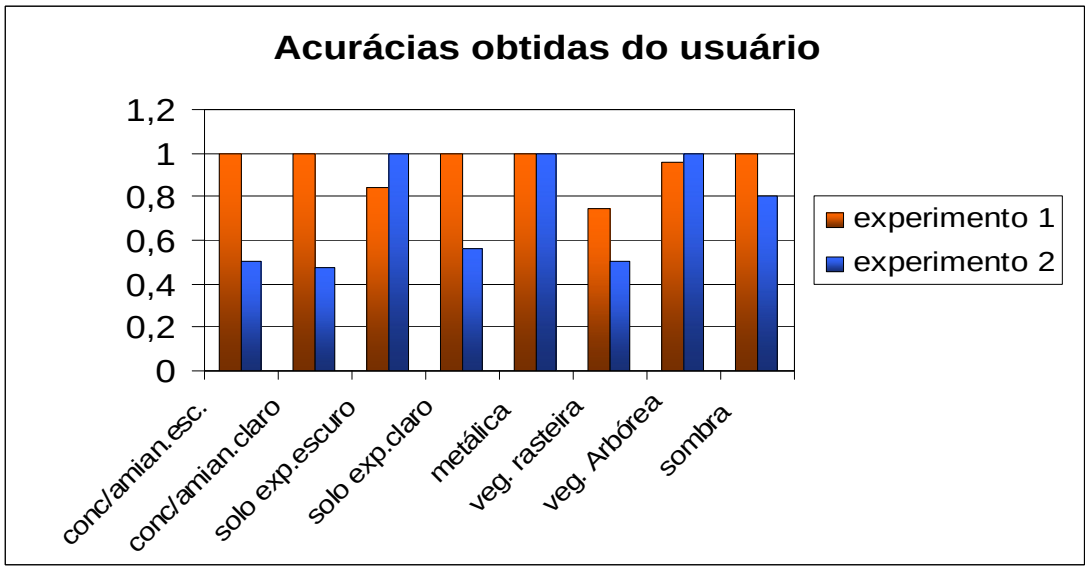

Gráfico 5: Comparação da acurácia do Usuário

Novamente, no gráfico 5 é possível verificar a diferença de comportamento entre os dois experimentos. O primeiro tem comportamento regular ficando com acurácia acima dos 80%, sendo que apenas a vegetação rasteira teve comportamento diferenciado deste percentual (75%), não deixando, portanto, de ser um bom resultado. O segundo, mostra que houve grande inclusão de pixels as classes vizinhas, resultado que já tinha sido mostrado pela matriz de erro e demais análises feitas por meio de gráficos. Nesse caso, têm-se dois extremos – três classes ausentes de erros de inclusão, enquanto que quatro apresentam altos índices para estes erros.

Apesar dos erros encontrados no resultado da classificação, após realizadas as análises necessárias, verifica-se a aplicabilidade da classificação orientada a objeto, com um desempenho satisfatório. As funções fuzzy adotadas

geraram um processo de classificação bem estável, podendo ser adaptado para outros locais.

5. CONCLUSÕES

Esse trabalho utilizou 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 como acontece nas áreas urbanas planejadas. Ter uma análise rápida da área, como a impermeabilidade do solo, a ocupação regular ou não do mesmo, auxiliaria muitas prefeituras brasileiras. Desta maneira, esta análise pode fornecer informações necessárias e de forma rápida para a área do planejamento urbano, como percentual de área de risco ocupada por favelas, áreas instaladas em mananciais entre outros, ajudando as Prefeituras no controle e intervenção dessas áreas, num curto espaço de tempo e a um menor custo.

Esse método possibilitou diferenciar feições que, apenas pela resposta espectral não seria possível, devido a grande heterogeneidade encontrada em áreas de favelas. Outros classificadores, já dispõem de ferramentas além das espectrais que facilitam a classificação, mas a utilização dos atributos, disponíveis no eCognition, na formação das funções de pertinência fuzzy ajudaram muito no processo de atribuir objetos às classes mais corretas. Um exemplo disso, é que permitem diferenciar alvos, que espectral ou textualmente não são discrimináveis, como solo exposto e telhados cerâmicos.

O intuito de testar a aplicabilidade do método de classificação de imagens orientada a objeto foi muito encorajador. Os resultados tanto na área teste quanto na de validação foram suficientemente satisfatórios, comparados aos processamentos convencionais, como o método de classificação por máxima

verossimilhança, citados em trabalhos anteriores como Antunes (2003); Pinho (2005).

Com a realização desta pesquisa, 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 pixel 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 muito bom numa imagem com uma resolução espacial próxima a do objeto. Assim, quanto maior for a escala da imagem, melhores serão seus resultados, e a classificação obtida terá feições mais próximas aos objetos reais, possibilitando, até medidas com grande precisão e acurácia.

O método pode ainda ser usado para outras cidades de porte médio a grande, como São Paulo, sendo apenas necessário alguns ajustes na rede hierárquica, principalmente no que tange os intervalos das funções.

É possível concluir que esse método pode ser utilizado para áreas heterogêneas e de difícil separabilidade, como é o caso das favelas, com um desempenho muito bom. Com o desenvolvimento de outros sensores que apresentam resoluções espaciais ainda melhores, tende-se a conseguir resultados ainda melhores que os aqui apresentados, que poderão ser usados até para atualização de plantas cadastrais, frisando que ainda é um sonho fazer medidas em imagens. Ainda não é possível fazer medidas nas classificações, pois as áreas delimitados num processo de classificação podem apenas ser estimadas e não oferecem absoluta precisão.

.

5.1 SUGESTÕES PARA TRABALHOS FUTUROS

Para trabalhos futuros sugere-se:

- Tentar por meio de atributos de forma, tais como: valores de área e relacionamentos entre classes (existência de quadras) não separar apenas áreas de favelas dentro do contexto urbano, como fazer a classificação de uso para áreas urbanas, principalmente as que contenham áreas de favela.

- Com as imagens tendendo a resoluções cada vez maiores devido aos novos sensores no mercado, como o Quickbird, por exemplo, então é sugerido testar novas classificações e até segmentações para áreas de favelas nesses sensores, para analisar e até comparar com os dados desta pesquisa.

- Buscar novas técnicas de avaliação da acurácia por regras fuzzy, pois há uma lacuna neste tema e merece estudos mais aprofundados.

- Comparar esta aplicação com outros métodos de classificação como redes neurais, maxver entre outros.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, M. A. P. DE; ABIKO, A. K. **Indicadores de Salubridade Ambiental em Favelas Localizadas em Áreas de Proteção aos Mananciais: O Caso da Favela Jardim Floresta.** São Paulo: EPUSP, 2000.28p.

ANDRADE, A. F.; BOTELHO, M. F.; CENTENO, J. A. S. Classificação de imagens de alta resolução integrando variáveis espectrais e forma utilizando redes neurais artificiais. In: Simpósio Brasileiro de sensoriamento Remoto, XI, 2003, Belo Horizonte. **Anais**... Belo Horizonte: INPE, 2003. p. 265-272.

ANTUNES, A. F. B. **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial**. 2003. 146p. Tese (Doutorado em Ciências Geodésicas) - Universidade Federal do Paraná, Curitiba.

ANTUNES, A. F. B. E LINGNAU, C. Determinação da acurácia temática de dados oriundos da classificação digital de objetos por meio de lógica fuzzy. In: Simpósio Brasileiro de Sensoriamento Remoto, XII, 2005, Goiânia. **Anais**...Goiânia: INPE, 2005. p. 3451-3459.

BAATZ, M. e SCHÄPE, A. Object-oriented and multi-scale image analysis in semantic networks. In: International symposium: Operacionalization of remote sensing, 2, 1999, Netherlands. **Anais**... Netherlands: Enschede, 1999.

BAATZ, M.; SCHÄPE, A. **Multiresolution Segmentation – na optimization approach for high quality multi-scale image segmentation**. In: STROBL, J., BLASCHKE, T. (hrsg): Angewandte Geographische informationsverarbeitung XII. Beiträge zum AGITSymposium Salzburg 2000. Karlsruhe. Hebert Wichmann Verlag, 2000. p. 12 – 23

BÄHR, P. **Models in philosophy and in image analysis**. Universität Karlsruhe, Institut für Photogrammetrie und Fernerkundung. ISPRS, extended abstract, comm. II, 2002.

BENZ, U., HOFMANN, P., WILLHAUCK, G., LINGENFELDER, I. AND M. HEYNEN: Multiresolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information . In: ISPRS **Journal of Photogrammetry & Remote Sensing** 58 (2004), 239-258.

BISHR, Y. **Semantic aspects of interoperable GIS**. ITC publication n 56, Enschede. 1997.

BLASCHKE, T., LANG, S., LORUP, E., STROBL, J., ZEIL, P.. Objectoriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications. In: Cremers, A., Greve, K. (Eds.), **Environmental Information for Planning, Politics and the Public**. Marburg: Metropolis-Verlag, 2000. vol. II, p. 555– 570.

BLASCHKE, T.; LANG, S.; MÖLLER, M. Object-based analysis of remote sensing data for landscape monitoring: recent developments. In: Simpósio Brasileiro de Sensoriamento Remoto, XII, 2005, Goiânia. **Anais**...Goiânia: INPE, 2005. p. 2879-2885.

BLASCHKE, T.; STROBL, J. What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. **GeoBIT/GIS**, n. 6, 2001.

BURROUGH, P.; FRANK, A. **Geographic objects with Inderterminate boundaries**. Francis & Taylor, 1996.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers, 1999. 136 p.

COSTA S. M.; SANCHES, R. Crescimento Urbano e Meio Ambiente: Uma Abordagem Metodológica Utilizando Geotecnologias. In: Simpósio Brasileiro de Sensoriamento Remoto, 11., 2001, Foz do Iguaçu. **Anais**... São José dos Campos: INPE, 2001. p. 1081-1088.

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. Segmentação multiresolução e classificação orientada a objeto de imagens SPOT. Disponível em: www.igeo.pt/igeo/portugueses/servicos/cdi/biblioteca/publicacoesigp_files/esig_2004/p068 . Acesso em: 23 de junho de 2005.

FEITOSA, R. Q.; MATTOS, C.;SANTOS, R. V. 1; REGO, L. F. G.; PEREIRA; A. A. C.; Impacto de técnicas baseadas em conhecimento na análise de imagens de média resolução para mapeamento do desflorestamento na Amazônia. In: Simpósio Brasileiro de Sensoriamento Remoto. **Anais**. Goiânia: INPE, 2005. v. , p. 4065 - 4072.

FLORENZANO, T. G.; **Imagens de Satélites para Estudos ambientais**. São Paulo: Oficina de Textos, 2002. 97 p.

FONSECA , L. G. M. et al. **Apostila de Processamento Digital de Imagens**. INPE. Junho, 2000.

FRANK, A. **Formal models for cognition- taxonomy of spacial location description and frames of reference.** Spacial Cognition: an interdiciplinary approach to representing and processing spatial knowledge. Edited by Christian Freksa, Christopher Habel e Karl Wender Springer-Verlag, Berlin. p293-336.1998.

GARCIA, G.J. **Sensoriamento Remoto: princípios e interpretação de imagens**. São Paulo: Nobel, 1982.

GONZALEZ, R.; WOODS, R. **Processamento de Imagens Digitais**. São Paulo: Ed. Edgard Blucher, 1992.

GOPAL, S.; WOODCOCK, C. **Theory and methods for accuracy assessment of thematic maps using fuzzy sets**. In: Photogrammetric Engineering and Remote Sensing. Vol. 60, nº 2. p.181-188. 1994.

GOUVÊA, R. A . R. **O espaço urbano e a clandestinidade: um estudo de caso dos loteamentos clandestinos no Município de São José dos Campos -SP**. Dissertação de Mestrado em Planejamento Urbano e Regional. UNIVAP. São José dos Campos, 2003

HEROLD, M.; GARDNER, M., HADLEY, B. AND ROBERTS, D. The spectral dimension in urban land cover mapping from high-resolution optical remote sensing data. In: Symposium on Remote Sensing of Urban Areas, 3, Istanbul, 2002 . **Anais** Istanbul, Turkey, 2002 .

HOFMANN, P. Detecting Informal Settlements from Ikonos Image Data using Methods of Object Oriented Image Analysis – An Example from cape Town (South Africa). 2nd **Remote Sensing of Urban Areas Internacional Symposium**. Regensburg/Alemanha: Instiut für Geographie an der universität Regensburg, 2001. p 107-118.

IBGE. Site IBGE Cidades@. 2005. Disponível: http://www.ibge.gov.br/cidadesat/default.php [capturado em 02 abr 2005

ISHIKAWA, M. I. **Potencialidades de uso de imagens IKONOS/geo para aplicações em áreas urbanas**. 2001. 82f. Dissertação (Mestrado em Ciências Cartográficas) – Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente.

JANSENN, L & MOLENAAR, M. **Terrain objects, their dynamics and their monitoring by integration of GIS and Remote Sensing**. IEEE transaction on Geocience and Remote Sensing. Vol.33. 1995.

JENSEN, J. R. Remote **Sensing of the Environment: an earth resource perspective**. Upper Sadle River – New Jersey: Prentice – Hall dos EUA, 2000.

JENSEN, J. R.; COWEN, D. C. Remote sensing of urban/suburban infrastructure and socio-economic attributes. **Photogrammetric Engineering & Remote Sensing**, v. 65, n. 5, p. 611-622, maio 1999.

JENSEN, J. **Introductory Digital Image Processing: A Remote Sensing Perspective**. Englewood Cliffs, New Jersey: Prentice-Hall. 1996.

KURDJIAN, M.de L. N. de O.; VALÉRIO FILHO, M. O uso de geotecnologias na obtenção de subsídios à regulamentação urbanística de loteamentos clandestinos. In: Simpósio Brasileiro de Sensoriamento Remoto, XII, 2005, Goiânia. **Anais**...Goiânia: INPE, 2005. p. 3779-3787.

LABA, M et al. Conventional and fuzzy accuracy assessment of New York gap analysis project land cover map. In **Remote Sensing of Environment**. 81 p.443-455. 2002.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159-174, 1977.

LILLESAND, T. M.; KIEFER, R. W.; **Remote sensing and image interpretantion**. New York: John Wiley and Sons, 1994. 117 p.

MAGALHÃES, M.N.; LIMA, A. C. Noções de probabilidade e estatística. 6ª ed. São Paulo: edusp, 2004.

MANSOR, S.; HONG, W.T.; SHAFIFF, A.R.M. Object oriented classification for land cover mapping. **23ª Asian Conference on remote sensing**, 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.

MARCHETTI, D. A. B.; GRACIA, G. J. Princípios de fotogrametria e fotointerpretação. São Paulo: Nobel, 1977.

MARICATO, E. **Brasil, cidades: alternativas para a crise urbana**. Petrópolis: Vozes, 2001.

MATHER, P. M. **Computer processing of remotely-sensed images: an introduction**. Chichester: John Wiley & Sons, 1999. 292 p. (Mather, 1999).

MEDEIROS, N. G. **Segmentação morfológica aplicada à cartografia**. 2003. 131p. Dissertação (Mestrado em Ciências Cartográficas) – Faculdade de Ciências e Tecnologia - Universidade Estadual Paulista, Presidente Prudente.

MEINEL, G.; NEUBERT, M.; REDER, J. The Potencial use of Very High Resolution Satellite Data for Urban Areas – First Experiences with Ikonos Data, their Classification and Application in Urban Planning and environmental Monitoring. In: Remote Sensing of Urban Areas Internacional Symposium, 2, 2001, Regensburg. **Anais**…Regensburg/Alemanha: Institut für Geographie an der universität Regensburg, 2001. p. 196-205

MOHAN, B. K.; KADAM, S. U.; RAO, E. P. Segmentation of High Resolution Imagery. **GIS Development**, v.7, n.11, 2003. p. 35-38

MOREIRA, Maurício Alves. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. 2ª Edição. São José dos Campos, SP, 2003. 250 p

NOVO, E. M. L. **Sensoriamento Remoto**: princípios e aplicações. 2ª ed. São Paulo, Edgard Blücher, 1989.

PINHO, C. M. D. de. **Metodologia de classificação orientada a objetos de uso da terra no espaço intra-urbano a partir de imagens orbitais de alta resolução espacial**. 2005. 168 f. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos.

PREFEITURA MUNICIPAL DE SÃO JOSÉ DOS CAMPOS. **Plano Diretor de Desenvolvimento Integrado**. São José dos Campos, 1994.

PREFEITURA MUNICIPAL DE SÃO JOSÉ DOS CAMPOS. **Plano Diretor de Desenvolvimento Integrado**. São José dos Campos, 2004.

QUINT, F. **Aerial image understanding using digital map-based semantic model**. Institut for Photogrametry and Remote Sensing. University of Karlsruhe, 1997.

RODRIGUES, R. M. **Cidades brasileiras do passado ao presente**. 5ª ed. São Paulo: Moderna, 1992.

SCHOWENGERDT, R., **Remote sensing models and methods for image processing**. San Diego: Academic Press, , 1997..

SCHULER, C. A. B.; ARAÚJO, L. L. Detecção de assentamentos irregulares em áreas de risco e classificação das habitações utilizando imagens anaglifo - uma forma de apoiar o planejamento urbano. In: Simpósio Brasileiro de Sensoriamento Remoto, XII, 2005, Goiânia. **Anais**...Goiânia: INPE, 2005. p. 3899-3905.

SILVA, E. A. 1995. 109p. **Extração de feições cartográficas de imagens multiespectrais fundidas.** (doutorado em engenharia) - Escola Politécnica da Universidade de São Paulo. USP, São Paulo

SILVA, J. C. da; RIBEIRO, C. A.; SANTOS, C. V. dos. Evolução das áreas de favelas do município de São José dos Campos – SP entre os anos de 1996 e 2004. In: Simpósio Brasileiro de Sensoriamento Remoto, XII, 2005, Goiânia. **Anais**...Goiânia: INPE, 2005. p. 1237-1244.

Space Imaging IKONOS imagery products and product guide [on line] Disponível em: www.spaceimaging.com/aboutus/satellites/IKONOS/ikonos.html. acesso em: junho de 2004.

TASCHNER, S. 1978. Favelas do município de São Paulo: resultados de pesquisa. In: Blay, E.A. **A luta pelo espaço**. Rio de Janeiro: Vozes, p.125-147.

VILLAÇA, F. **Espaço Intra-urbano no Brasil**. São Paulo: Studio Nobel: FAPESP: Lincoln Institute, 1998.

VILLAÇA, F. **O que todo cidadão precisa saber sobre habitação**. São Paulo: Global, 1986.

WIEGAND, C.L.; RICHARDSON, A.J.; ESCOBAR, D.E.; GERBERMANN, A.H. **Vegetation indices in crop assessments**. In: Remote Sensing of Environment. Vol. 35 pp 105-119. fev-mar de 1991.

WILLHAUCK, G. **Comparison of objected oriented classification techniques and standard image analysis for use of change detection between Spot a multispectral satellite images and aerial photos**. ISPRS vol XXXXIII, Part B3. Amsterdam. 2000. 1 CDROM.

ZADEH, L. **Fuzzy Sets.** Inform. Contr. Vol 8. 338-353pp. 1965.

ZHAN, Q.; MOLENNAR, M.; TEMPFLI, K. Hierarchical object based structural analysis toward urban land use classification using high-resolution imagery and airbone LIDAR data. **International Archives of Photogrammetry and Remote Sensing**, n. 33, Part 7: 1751-175, 2002.

7. BIBLIOGRAFIA

ALMEIDA, J.F. **Ortofoto Digital**. 1989. 100 f. Dissertação (Mestrado em Ciências Geodésicas) **–** Universidade Federal do Paraná, UFPR, Curitiba.

ANCAROLA, M.F. Proyecto ortofotocarta digital "ciudade de Buenos Aires". **Revista Cartográfica.** México, n. 68, p.51-59, jun. 1999.

ANDERSON, J. R.; HARDY, E. E.; ROACH, J. T.; WITMER, R. E. **Sistema de classificação do uso da terra e do revestimento do solo para utilização com dados de sensores remotos**; trad. Por Herold Strang. **–** Rio de Janeiro: IBGE, 1979. 80 p.

BADIRU, A. I.; PIRES, M. A. F.; RODRIGUEZ, A. C. M.. Método para a Classificação Tipológica da Floresta Urbana visando o Planejamento e a Gestão das Cidades. In: Simpósio Brasileiro de Sensoriamento Remoto, XII, 2005, Goiânia. **Anais**...Goiânia: INPE, 2005. p. 1427-1433.

BINAGHI, E. GALLO, I e PEPE, M. A neural adaptive for feature extration and recognition in high resolution remote sensing imagery. . **International Journal de Remote Sensing**, v. 24, n. 20, 2003. p.3947 **–** 3959.

BINAGHI, E.; BRIVIO, P.A.; GHEZZI, P.; RAMPINI, A.; ZILIOLI, E. Investigating the behavior of neural and fuzzy-statistical classifiers in sub-pixel land cover estimations. **Canadá Journal of Remote Sensing** v. 25 nº 02. Canadá: Publicado por Canadian aeronautics and Space institute, 1999.

BLASCHKE, T; HAY, G. Object-oriented image analysis and scale-space: theory and methods for modelling and evaluating multiscale landscape structure. jan. 2002. Disponível em: www.definiens-imaging.com/documents/reference2002.htm . Acesso em 25 junho 2005.

BUENO, L. da S.; LAPOLLI, E. M.. Determinação de áreas de ocupação de risco: auxilio e planejamento urbano com utilização das técnicas de Sensoriamento

Remoto e Geoprocessamento. In: SIMPÓSIO LATINO AMERICANO DE PERCEPCCION REMOTA, IX, 2000. Puerto Iguazú. **Memórias.** Puerto Iguazú: Sociedad de especialistas Latinoamericanos en percepción remota y sistemas de información espacial, 1990.

CASTELLS, M. **La question urbaine**. Librarie Francois Maspero.(Trad. port. de Arlene Caetano. A questão urbana). Rio de Janeiro, Paz e Terra, 1972, 228-236 p.

COSTA, T.C.C. **Avaliação de estratégias para classificação de imagens orbitais em mapeamento de uso e cobertura da terra**. 1999. 109 p. Dissertação (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa. 1999.

CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: Unicamp, 1992.

CRUZ, N. C. **Uma análise da infestação por plantas aquáticas utilizando imagens multiescala e redes neurais artificiais.** Dissertação (Mestrado em Ciências Cartográficas) - Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista: Presidente Prudente, 2005.

FERRARI, F. B..; LAPOLLI, E. M.. Uma proposta de avaliação da expansão urbana na Ilha de Santa Catarina utilizando técnicas de Sensoriamento Remoto. In: SIMPÓSIO LATINO AMERICANO DE PERCEPCCION REMOTA, IX, 2000. Puerto Iguazú. **Memórias.** Puerto Iguazú: Sociedad de especialistas Latinoamericanos en percepción remota y sistemas de información espacial, 1990.

GALO, M. DE L. B. T. **Notas de aula da disciplina: interpretação de imagens aplicada a geografia.** Curso de Graduação em Geografia, FCT, UNESP. Presidente Prudente, não publicado, 2002.

GAMBA, P. e DELL'ACQUA, F. Increased accuracy multiband urban classification using a neuro-fuzzy classifier. . **International Journal de Remote Sensing**, v. 24, n. 04, 2003. p.827 – 834.

GARCIA, L. M. F. et al. **Apostila de Processamento Digital de Imagens**. INPE. Junho, 2000.

MOLENAAR, Martien. **An introduction to the theory of object Modelling for GIS**. Taylor&Francis, 1998.

PEÑA, M. S.; SERAFINI, M.C. Estado de la teledeteccion satelitaria en la decada del 90. **Revista SELPER**, vol.8, n 1, p.15-18, março 1992.

PINHO, C. M. D. de; KUX, H. J. H. Dados do Quickbird para subsidiar o planejamento urbano: uma proposta metodológica, São José dos Campos, SP, Brasil. In: Simpósio Brasileiro de Sensoriamento Remoto, XII, 2005, Goiânia. **Anais**...Goiânia: INPE, 2005..

RICHARDS, J. A. **Remote Sensing Digital Image Analysis – An Introduction**. Berlin: Springer-Verlag., 1986.

SILVA, E.A. **Notas de aula da disciplina: sensoriamento remoto aplicado à geografia.** Curso de Graduação em Geografia, FCT, UNESP. Presidente Prudente, 2001. Não Publicado.

VIEIRA, J. M.; KAZMIERCZAK, M. L.; MALTA, F. J. N. C. Proposta metodológica para identificação de áreas de risco de movimentos de massa em áreas de ocupação urbana. Estudo de caso: Campos do Jordão, SP. In: Simpósio Brasileiro de Sensoriamento Remoto, XII, 2005, Goiânia. **Anais**...Goiânia: INPE, 2005. p. 3935-3942.

WILLHAUCK, G, BENZ, U, SIEGERT, F. **Semiautomatic classification procedures for FIRE monotoring using multitemporal SAR images and NOAA-AVHRR hotspot data**. Definiens digital paper. Munich 2002.