

GERMÁN TORRIJOS CADENA



**CLASSIFICAÇÃO DOS TIPOS DE PAVIMENTOS
DAS VIAS URBANAS A PARTIR DE IMAGEM
DE ALTA RESOLUÇÃO ESPACIAL POR MEIO DE
ANÁLISE ORIENTADA A OBJETO**

DISSERTAÇÃO DE MESTRADO

**PRESIDENTE PRUDENTE
2011**



UNIVERSIDADE ESTADUAL PAULISTA

**Faculdade de Ciências e Tecnologia
Pós-Graduação em Ciências Cartográficas**

GERMÁN TORRIJOS CADENA

**CLASSIFICAÇÃO DOS TIPOS DE PAVIMENTOS
DAS VIAS URBANAS A PARTIR DE IMAGEM
DE ALTA RESOLUÇÃO ESPACIAL POR MEIO DE
ANÁLISE ORIENTADA A OBJETO**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Cartográficas da Universidade Estadual Paulista, Campus de Presidente Prudente, como parte dos requisitos para obtenção do título de Mestre em Ciências Cartográficas.

MARIA DE LOURDES BUENO TRINDADE GALO

Orientadora

PRESIDENTE PRUDENTE

2011




	Torrijos Cadena, Germán. T65c Classificação dos tipos de pavimentos das vias urbanas a partir de imagem de alta resolução espacial por meio de análise Orientada a Objeto / Germán Torrijos Cadena. - Presidente Prudente: [s.n], 2011 114 f. : il. Dissertação (mestrado) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia Orientadora: Maria de Lourdes Bueno Trindade Galo. Banca: Alzir Felipe Buffara Antunes, Amilton Amorim. Inclui bibliografia 1. Cartografia. 2. Orientação a Objeto. 3. Ortoimagem. I. Autor. II. Universidade Estadual Paulista. Faculdade de Ciências e Tecnologia. III. Título. CDD 621.71
--	--


Ficha catalográfica elaborada pela Seção Técnica de Aquisição e Tratamento da Informação – Serviço Técnico de Biblioteca e Documentação - UNESP, Câmpus de Presidente Prudente. claudia@fct.unesp.br




BANCA EXAMINADORA



PROFA. DRA. MARIA DE LOURDES BUENO T. GALO
(ORIENTADORA)



PROF. DR. ALZIR FELIPPE BUFFARA ANTUNES
(UFPR-PR)



AMILTON AMORIM
(FCT/UNESP)



GERMÁN TORRIJOS CADENA

PRESIDENTE PRUDENTE (SP), 15 DE FEVEREIRO DE 2011.

RESULTADO: APROVADO

Dedico:

Principalmente para minha mãe Magdalena Cadena
e especialmente para: María Eugenia, Camila, Ana Sofia,
Yina, Angy, Myriam e María Isabel.
A Sarita que nasceu nestes dias.



AGRADECIMENTOS

A DEUS, porque ele estive sempre nos momentos difíceis.

A Prof^a. Dr^a. Maria de Lourdes Bueno Trindade Galo, por ter aceitado a minha orientação como estudante estrangeiro, pela sua dedicação e ensino profissional.

Ao Prof. Dr. Antonio Maria Garcia Tommaselli, por suas orientações como coordenador do programa de Pós-Graduação em Ciências Cartográficas (PPGCC), da Universidade Estadual Paulista (UNESP).

Aos professores do Departamento de Cartografia, Matemática e demais, pela formação, competência e qualidade no ensino.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão da bolsa de estudos durante o ultimo ano no desenvolvimento desta pesquisa.

Ao Governo do Brasil pela oportunidade que fornece aos países em desenvolvimento.

À Universidade Estadual Paulista (UNESP) e ao Programa de Pós-Graduação em Ciências Cartográficas (PPGCC), pela excelente qualidade e competência no ensino ao nível mundial.

Aos colegas do PPGCC, pelo apoio e bons momentos compartilhados.

Aos membros da banca de qualificação, Prof. Dr. JÚLIO KIYOSHI HASEGAWA e Prof. Dr. AMILTON AMORIM, pelas valiosas sugestões.

À Eng. Msc. Fernanda de Almeida Prado, pelas correções e boa vontade em sua ajuda.

À Eng. Msc. Cristina Aparecida Beneditti pelas orientações no manejo do software Ecognition.

Ao engenheiro Jaime Duarte, do Instituto Geográfico “Agustín Codazzi” de Colômbia pelas sugestões, colaboração e bons conselhos.

Ao Eng. William Rodriguez Mateus, pela colaboração no fornecimento da informação digital e apoio Profissional.

À universidade Distrital “Francisco José de Caldas” de Bogotá, Colômbia pelo afastamento para a realização do curso de mestrado.

Ao Instituto Geográfico “Agustín Codazzi” da Colômbia, pelo fornecimento das imagens de Bogotá, Colômbia.



Muito estudar não basta para nos ensinar a compreender.

(Heráclito de Éfeso)

El ignorante afirma, el sabio duda y reflexiona.

(Aristóteles)



RESUMO

A circulação de veículos na cidade de Bogotá, capital da Colômbia, é muito alta, principalmente por este ser o centro de convergência do sistema de transportes, além de ser o pólo comercial, cultural e industrial do país. Com o crescimento urbano e econômico da cidade, o número de veículos que trafega nela vem aumentando, ano após ano, principalmente na região metropolitana. Em decorrência desse aumento, está sendo observada a deterioração, cada vez maior, das vias urbanas da cidade, tornando necessário buscar alternativas que possam mitigar este problema. Neste contexto, a proposta central desta pesquisa é classificar os tipos de pavimentos das vias urbanas, de Bogotá, fazendo uso de ortoimagens fornecidas pelo Instituto Geográfico “Agustín Codazzi” da Colômbia, adquiridas com uma câmara Vexcel Ultracam-D de alta resolução espacial, com o propósito de encontrar uma alternativa para mapear as vias que necessitam ser restauradas. Para testar a metodologia, foi feita a classificação de um setor do centro da cidade utilizando a técnica de análise de imagens orientada a objeto (*object-based image analysis* - OBIA), implementada no *software Ecognition*. Os resultados obtidos mostraram que foi possível identificar as vias que necessitam de especial atenção com a elaboração do mapa temático da classificação do setor de estudo.

Palavras-chave: função fuzzy, OBIA, GEOBIA, Orientação a Objeto, Ortoimagem.

ABSTRACT

The flow of vehicles in Bogotá, capital city of Colombia, is really intense, mainly for the city being the converging center of the transportation system, furthermore, being the countries' commercial, cultural and industrial pole. Because of the urban and economic growth, the number of vehicles which are driven in that city have been increasing year after year, mainly in the metropolitan area. Due to this increase, it has been observed, each time more, the deterioration of urban ways, becoming necessary to look for alternatives which can reduce this problem. Within this context the main proposal of this research is to classify the types of pavements of Bogota's urban ways. It'll make use of orthoimages provided by the Geographical Institute "Agustín Codazzi" from Colombia. These picture were taken with a spacial resolution camera named Vexcel Ultracam-D, intending to find an alternative for mapping the ways which need to be restored. In order to test this methodology, a sector in the city center has been classified using the object-based image analysis technique, implemented in the software Ecognition. The results obtained show us that it was possible to identify the ways that need special attention concerning the elaboration a classifying thematic map of the area being studied.

Key- words: fuzzy function, OBIA, GEOBIA, Object-orientation, Orthoimage.

LISTA DE FIGURAS

Figura 1– Modelo conceitual da classificação orientada a objeto.....	23
Figura 2 – Princípio da rede hierárquica em diferentes escalas.	27
Figura 3 – Rede hierárquica de tipos de vegetação intraurbana.....	27
Figura 4 – Diagrama conceitual da segmentação multiresolução.	34
Figura 5 – Descritores em <i>Ecognition</i> , exemplo: “Características dos Objetos”.	39
Figura 6 – Tipos de funções de pertinência <i>Booleana e Fuzzy</i>	40
Figura 7 – Função de pertinência para a variável linguística distância.....	41
Figura 8 – Representação matemática da matriz de confusão.....	45
Figura 9 – Localização geral da área de interesse.....	51
Figura 10 – Localização específica da área de estudo.	52
Figura 11– Área-teste.....	53
Figura 12 – Câmara Vexcel-UltraCam D.....	55
Figura 13 – Procedimento metodológico.	56
Figura 14 – Ilustração das três bandas espectrais RGB e imagens componentes principais.....	58
Figura 15 – Exemplo de uma segmentação com o arquivo vetorial.	61
Figura 16 – Segmentação da ortoimagem (a), (b), ...	65
Figura 17 – Classes de interesse.....	66
Figura 18 – Função booleana da área.....	67
Figura 19 – Proporção de segmentos gerados por classe de interesse.	78
Figura 20 – Seleção dos segmentos na imagem e no mapa vetorial.	79
Figura 21 – Classificação área-teste e área de estudo.	82
Figura 22 – Quadras e vias originais (a), (b), (c).	83
Figura 23 – Área de estudo	84
Figura 24 – Mapa da área de estudo classificado com os tipos de	85
Figura 25 – Mapa da área de estudo classificado com os tipos de	86
Figura 26 – Imagem com exemplos da classificação (a), (b).....	88
Figura 27 – Coeficiente <i>kappa</i> para cada classe.	92
Figura 28 – Utilização do descritor espacial das quadras (a),(b).	94
Figura 29 – Estabilidade da classificação dos tipos de pavimentos das vias.	95
Figura 30 – Imagem classificada (a), (b), (c).	98

LISTA DE TABELAS

Tabela 1 – Parâmetros baseados em valores espectrais.	36
Tabela 2 – Parâmetros baseados na forma.	37
Tabela 3 – Coeficiente <i>Kappa</i> e desempenho da classificação.	50
Tabela 4 – Coordenadas planas da ortoimagem - Datum Magna Sirgas.....	53
Tabela 5 – Especificações da ortoimagem utilizada na pesquisa.	54
Tabela 6 – Número de elementos amostrais selecionados para a análise.....	78
Tabela 7 – Matriz de confusão da classificação das classes de interesse.....	90
Tabela 8 – Índices de exatidão por classe.	91
Tabela 9 – Matriz de confusão da classificação das classes.....	93
Tabela 10 – Matriz de confusão da classificação das classes de.....	94
Tabela 11 – Indicadores estatísticos de Estabilidade.	96



LISTA DE QUADROS

Quadro 1 – Chave de interpretação.	59
Quadro 2 – Teste de segmentação escala 10, 20, 30;	62
Quadro 3 – Teste de segmentação escala 10, 20, 30;	63
Quadro 4 – Teste de segmentação escala 40, 50, 60;	64
Quadro 5 – Descritores e funções de pertinência para a classe Asfalto.	68
Quadro 6 – Descritores e funções de pertinência para a classe Concreto_a.	69
Quadro 7 – Descritores e funções de pertinência para a classe Concreto_b.	70
Quadro 8 – Descritores e funções de pertinência para a classe Terra.	71
Quadro 9 – Descritores e funções de pertinência para a classe Quadras.....	72
Quadro 10 – Informação dos objetos na imagem.....	73
Quadro 11 – Especificação da função de pertinência.....	77
Quadro 12 – Parâmetros usados para a segmentação- único nível.....	81
Quadro 13 – Composição colorida RGB (1,2,3), fotografias <i>in loco</i> e classificação.....	89



SUMÁRIO

1	INTRODUÇÃO	15
2	OBJETIVOS	16
3	JUSTIFICATIVA	17
4	FUNDAMENTAÇÃO TEÓRICA.....	19
4.1	EXTRAÇÃO DE INFORMAÇÕES A PARTIR DE IMAGENS	19
4.2	CLASSIFICAÇÃO ORIENTADA A OBJETO	22
4.2.1	CARACTERIZAÇÃO DOS OBJETOS	25
4.2.2	CARACTERIZAÇÃO DE CLASSES.....	25
4.2.3	SEGMENTAÇÃO	29
4.2.3.1	Segmentação multiresolução	30
4.2.4	CLASSIFICAÇÃO DOS OBJETOS.....	35
4.3	ANÁLISE DA CONFIABILIDADE DA CLASSIFICAÇÃO	43
4.3.1	MATRIZ DE CONFUSÃO E COEFICIENTE DE CONCORDÂNCIA KAPPA.....	44
5	MATERIAL E MÉTODO	51
5.1	ÁREA DE ESTUDO.....	51
5.1.1	SELEÇÃO DA ÁREA-TESTE	53
5.2	MATERIAL	54
5.3	PROCEDIMENTO METODOLÓGICO.....	56
5.3.1	GERAÇÃO DAS IMAGENS DE COMPONENTES PRINCIPAIS	57
5.3.2	CARACTERIZAÇÃO DAS CLASSES	58
5.3.3	SEGMENTAÇÃO	61
5.3.4	DEFINIÇÃO DAS CLASSES DE INFORMAÇÃO	65
5.3.5	DEFINIÇÃO DE ATRIBUTOS E REGRAS DE PERTINÊNCIA.....	66
5.3.6	CLASSIFICAÇÃO	75
5.3.7	AVALIAÇÃO DA CLASSIFICAÇÃO.....	77
6	RESULTADOS E ANÁLISES.....	81
6.1	RESULTADOS INTERMEDIÁRIOS	81
6.1.1	PARÂMETROS DA SEGMENTAÇÃO MULTIRESPOLUÇÃO	81
6.2	ÁREAS CLASSIFICADAS	82
6.3	ANÁLISE QUALITATIVA.....	87
6.4	ANÁLISE QUANTITATIVA	90
7	CONCLUSÕES	99

8 RECOMENDAÇÕES.....	101
REFERÊNCIAS BIBLIOGRÁFICAS	102
APÊNDICE A.....	109
APÊNDICE B... ..	113

1 INTRODUÇÃO

Os atuais sistemas de Sensoriamento Remoto, orbitais e aerotransportados, caracterizam-se pela capacidade de gerar dados com potencial de discriminar, cada vez melhor, os alvos da superfície terrestre, devido ao aumento, principalmente, nas suas resoluções espacial e espectral. A disponibilidade de dados de alta resolução espacial vem ampliando sobremaneira a possibilidade de estudos urbanos que empregam essa tecnologia, tanto para o mapeamento da cobertura da terra, quanto para a definição e caracterização do uso do solo urbano. Dessa forma, a utilização desses dados em áreas urbanas cresce à medida que as potencialidades do Sensoriamento Remoto são demonstradas e confirmadas, nas mais diferentes aplicações.

A caracterização espacial, espectral e radiométrica dos objetos, a serem analisados a partir de imagens digitais, obtidas por sensores, aerotransportados, é um aspecto importante a ser considerado nos estudos intraurbanos, com o aumento das resoluções dos sensores instalados a bordo das novas câmaras aéreas digitais. O detalhamento proporcionado pela melhor resolução espacial permite a análise e o mapeamento dos ambientes urbanos com maior possibilidade para a categorização dos alvos intraurbanos.

Atualmente, o uso de técnicas automáticas e semi-automáticas para a extração de informações urbanas e intraurbanas de imagens de alta resolução espacial vem sendo alvo de diversos estudos, com destaque para as técnicas baseadas em análise orientada a objeto (*Object Based Image Analysis - OBIA*), (MESEV, 2003; BLASCHKE; LANG; HAY, 2008).

Pinho (2005) identificou os atributos que melhor descrevem as classes de cobertura do solo intraurbano empregando a OBIA. A autora elaborou redes semântica e hierárquica para um estudo de caso específico, mostrando a complexidade presente nos diferentes elementos que compõem a cobertura desse ambiente. Os resultados obtidos na classificação são um indicativo de que a OBIA é uma alternativa viável para a obtenção de informações, a partir de imagens de forma mais rápida e menos subjetiva.

Hoje, um dos principais esforços por parte da comunidade de pesquisadores em Sensoriamento Remoto têm sido a concepção e a avaliação de metodologias de classificação automática ou semi-automática da cobertura do solo urbano (DARWISH et al., 2003; SANDE et al., 2003; PINHO; FEITOSA; KUX, 2005; ARAÚJO; KUX,

2006; COSTA et al., 2007). Assim, a GEOBIA (*Geography Object Based Image Analysis*), uma nova abordagem que integra as ciências de informação geográfica, com base na utilização de métodos de classificação automáticos e semi-automáticos que propiciam a adoção de parâmetros espaciais, espectrais e radiométricos, tem sido cada vez mais estudada e aplicada pela comunidade da área de Sensoriamento Remoto.

Finalmente, a aplicação da GEOBIA conduz ao objetivo essencial, que é desenvolver e aplicar a teoria, métodos e ferramentas para replicar e ajudar a interpretação humana das imagens de Sensoriamento Remoto, processos, automatizados ou semi-automáticos que se traduzem em aumento da produção, diminuição de tempo, subjetividade, e benefícios de custos (GEOBIA, 2008).

Considerando o exposto, propõe-se a aplicação da OBIA, na classificação dos tipos de pavimentos das vias urbanas para um setor da cidade de Bogotá, Distrito Capital, uma vez que se dispõe de uma ortoimagem com elemento de resolução espacial no terreno de 0,15 m, que aponta para a necessidade de uma classificação dos alvos da cena não somente pelas suas características espectrais, mas também espaciais.

2 OBJETIVOS

Esta pesquisa tem por objetivo principal classificar os tipos de pavimentos das vias urbanas, a partir de uma ortoimagem aérea, usando a abordagem de classificação orientada a objeto.

Nesse contexto, são definidos os seguintes objetivos específicos:

- Apresentar um estudo de caso, considerando uma pequena área da cidade de Bogotá, Colômbia;
- Analisar a qualidade da classificação obtida.

3 JUSTIFICATIVA

A circulação de veículos na região metropolitana da cidade de Bogotá, capital da Colômbia, é muito alta, principalmente por ser este o centro de convergência do sistema de transporte do país, além do constituir um pólo comercial, cultural e industrial. Com o crescimento urbano e econômico da cidade, o número de veículos em circulação vem aumentando, ano após ano, principalmente nas proximidades do centro.

Em decorrência desse aumento no tráfego de veículos, observa-se uma deterioração cada vez maior das vias urbanas de Bogotá. Estudos apresentados em dezembro de 2008, pelo Conselho de Bogotá e pelo Instituto de Desenvolvimento Urbano (IDU), mostraram que, dos 14.483 km da rede viária, 49% (7.096,67 km) estavam em estado ruim de conservação. Para mudar essa situação, o sistema viário precisa passar por estudos urgentes, que se apliquem conforme as condições técnicas e econômicas das áreas afetadas na cidade.

Para auxiliar na solução desse problema, há uma demanda crescente por informações espaciais precisas e atualizadas, as quais podem ser adquiridas por técnicas de Sensoriamento Remoto, visando o monitoramento, à análise e o mapeamento das áreas urbanas e intraurbanas da capital Colombiana e das demais cidades do país. Pensando nisso, o Instituto Geográfico “Agustín Codazzi” (I.G.A.C), da Colômbia, adquiriu uma câmara *Vexcel Ultracam-D* para apoiar o planejamento dos municípios, através do fornecimento das ortoimagens, adquiridas em escala regional e urbana, e da elaboração de mapas temáticos de uso e cobertura da Terra.

Em consonância com essa iniciativa do I.G.A.C, esta pesquisa propõe o desenvolvimento de um procedimento, para testar a aplicabilidade da análise orientada a objeto na classificação dos tipos de pavimentos das vias urbanas no centro da cidade de Bogotá, utilizando como fonte uma ortoimagem obtida com a câmara *Vexcel Ultracam-D*.

Ao avaliar a aplicabilidade da análise orientada a objeto, partindo do pressuposto que diversos trabalhos (Pinho, 2005; Costa et al., 2007) e as aplicações relatadas por Blaschke e Kux (2007), demonstraram seu êxito em aplicações urbanas e intraurbanas, considerou-se importante apresentar essa abordagem ao Instituto Geográfico e o Instituto de Desenvolvimento Urbano de Bogotá.

Alem disso, dos trabalhos anteriores relacionados com a detecção da malha viária na periferia urbana de São Paulo utilizando imagens de alta resolução espacial e classificação orientada objeto, vale destacar a pesquisa de doutorado desenvolvida por Nóbrega (2007), cujo objetivo geral foi propor uma metodologia que utiliza regras de classificação baseada em conhecimentos atribuídos aos objetos extraídos da imagem, característicos da ocupação do solo na periferia urbana da cidade de São Paulo.

Recentemente, destaca-se a dissertação de mestrado de Resende (2010), intitulado “Investigação do uso de imagens de sensor de Sensoriamento Remoto hiperespectral e com alta resolução espacial no monitoramento da condição de uso de pavimentos rodoviários”, que teve como objetivo principal a investigação da utilização de imagens digitais de alta resolução espacial e espectral no monitoramento da condição de uso dos pavimentos asfaltados. O resultado obtido mostrou entre outros objetivos que a utilização das melhores técnicas existentes da classificação de imagens, misturando a classificação pixel a pixel com a classificação baseada em objetos, gera os índices da qualidade do asfalto para ser comparados com os índices já normalizados pelos órgãos competentes.

Os trabalhos anteriores mostram o crescente sucesso da classificação de imagens baseada em objetos, a qual vem estimulando os pesquisadores a criar novos meios de superar a limitação das tradicionais técnicas de classificação de imagens.

4 FUNDAMENTAÇÃO TEÓRICA

4.1 EXTRAÇÃO DE INFORMAÇÕES A PARTIR DE IMAGENS

Uma das fontes tradicionais de dados para a confecção de mapas temáticos são as imagens de Sensoriamento Remoto. A extração de informações nessas imagens pode ser realizada por meio de procedimentos de interpretação visual ou por métodos de classificação semi-automáticos, que são os principais empregados atualmente. Dependendo da técnica adotada para a extração de informações, pode-se incrementar ou reduzir o poder de discriminação (ANTUNES, 2003), o qual considera não apenas a resolução espacial e espectral da imagem, mas também do contexto. Números adicionais de bandas derivadas, tal como textura ou modelo digital do terreno, podem sobremaneira realçar a discriminação de algumas feições (RICHARDS; JIA, 1999).

Em alguns casos, transformações realizadas com as bandas espectrais podem melhorar a descrição da informação de interesse e facilitar sua extração. A análise de Componentes Principais é uma transformação linear aplicada ao conjunto de bandas de uma imagem multiespectral que permite a redução ou remoção de redundâncias entre bandas espectrais através da rotação e translação dos eixos no espaço de atributos espectrais. Por meio de uma transformação matemática, gera-se um novo conjunto de dados não correlacionados que apresentam, decrescentemente, uma redução percentagem de variabilidade das informações contidas nas bandas originais. Esse procedimento garante a separabilidade espectral dos objetos presentes na cena e é uma maneira de se prospectar informação sobre objetos urbanos em imagens de sensoriamento remoto (NÓBREGA, 2007).

O número de componentes principais gerado é igual ao número de bandas espectrais utilizadas e estas são ordenadas de acordo com o decréscimo da variância de nível de cinza. A primeira componente principal tem a maior variância (maior contraste) e a última, a menor variância. A transformação em duas dimensões do componente principal corresponde à rotação do eixo original da coordenada para coincidir com as direções de máxima e mínima variância no dado (INPE, 2011).

Por outro lado, com o lançamento de satélites com sensores de alta resolução espacial e a fabricação de câmaras aerotransportadas com resoluções espaciais

ainda maiores, foram impostos novos desafios para a extração de informação de uso e cobertura do solo urbano e rural. As tradicionais abordagens de classificação no nível espectral tornam-se limitadas para esses tipos de imagens que captam detalhes de cenas muito heterogêneas e com grande variação interna das classes (MEINEL; NEUBERT, 2005).

Surge, portanto, a necessidade de métodos alternativos de extração temática que não se limitem aos atributos espectrais. Dentre esses métodos, destaca-se a análise orientada a objeto, que permite a inserção do conhecimento do analista e a utilização de parâmetros de cor, forma, textura, padrão e contexto, no processo de classificação. A abordagem orientada a objeto considera informações de objetos (ou segmentos) extraídos de uma imagem, no processo de classificação baseado em conhecimento (KIM; XU; MADDEN, 2008). Trata-se de uma técnica relativamente recente, pesquisada e recomendada na literatura (EASTMAN, 2006; YU et al., 2006; BLASCHKE; LANG; HAY, 2008).

A introdução do conhecimento no processo de classificação pode ajudar a superar as dificuldades na extração de informação de imagens de resolução espacial alta e muito elevada. Sistemas baseados em conhecimento são aqueles que modelam, em um ambiente computacional, o conhecimento do analista combinando dados de diferentes fontes e formatos na análise de imagens de sensores remotos (FEITOSA et al., 2005).

Enquanto algoritmos convencionais de classificação de imagens distinguem grupos de *pixels* com características espectrais semelhantes, as quais individualmente não se traduzem em objetos reais, na abordagem baseada em conhecimento, o objetivo é identificar objetos que têm uma existência concreta no mundo real e que expressam características próprias na imagem analisada (PINHO, 2005).

O funcionamento desses sistemas baseia-se na introdução do conhecimento do analista a respeito da cena, ou seja, é uma formalização da “visão” de um determinado indivíduo sobre uma cena específica. Assim, o resultado da classificação é um reflexo do conhecimento (informações coletadas *a priori* sobre a área a ser classificada) e da capacidade de compreensão do analista (fortemente influenciada por sua formação profissional e experiência laboral) a respeito de uma determinada cena (ANTUNES, 2003).

Os sistemas fundamentados em conhecimento constituem-se em importantes ferramentas para profissionais de diversas áreas que utilizam a paisagem como foco de

análise nas imagens de Sensoriamento Remoto (geógrafos, geólogos, cartógrafos; etc.). A utilização desses sistemas na extração de informações a partir de imagens orbitais vem sendo empregada há algum tempo: SPAM; SIGMA; MESSIE; AINDA; (PINHO 2005). Esses sistemas integram, em combinações variadas, os seguintes itens: algoritmos de segmentação; estruturação de classes na forma de redes semânticas; classificação baseada em regras e possibilidade de integração de imagens multisensores e/ou dados vetoriais (PINHO, 2005).

Para Mitri e Gitas (2004), a classificação orientada a objeto foi desenvolvida para superar as limitações dos métodos tradicionais de extração de informação quando se usa imagem de alta resolução espacial. Os autores realizaram uma pesquisa para avaliar o desempenho da classificação orientada a objeto no mapeamento de áreas queimadas na ilha grega de Thasos usando dados TM-LANDSAT, na qual constataram que o mapa das áreas de queimadas apresentou uma exatidão global de 97,69% com imagens não corrigidas topograficamente e um acréscimo de 1,16% na classificação com as imagens corrigidas.

Pinho (2005) aplicou análise orientada a objeto na classificação de cobertura do solo intraurbano com dois tipos de imagens orbitais de alta resolução espacial (IKONOS II e QuickBird). A área-teste localiza-se no município de São José dos Campos, SP. Os resultados das classificações revelaram que esse tipo de abordagem apresenta um bom potencial na classificação de cobertura do solo urbano a partir de imagens orbitais de alta resolução espacial.

Um dos estudos pioneiros no Brasil, em classificação orientada a objeto aplicada a imagens de alta resolução espacial foi o de Antunes (2003). O estudo visou o mapeamento de tipologias vegetais em ambiente ciliar do rio Paracatu, município de Nova Esperança, Paraná, com imagens Ikonos. O autor comparou os resultados obtidos por métodos tradicionais de classificação automática baseados em *pixels*, como máxima verossimilhança e lógica *fuzzy* e a classificação orientada a objeto, tendo verificado a superioridade desta última. Salientou a importância da inserção do conhecimento no processo de classificação, que possibilitou melhorar a precisão dos resultados, enfatizando que a metodologia foi eficiente para a classificação de mata ciliar e outros usos circunvizinhos como área urbana e agricultura.

Estes e outros estudos confirmam a grande potencialidade da extração da informação com adoção da abordagem da classificação orientada a objeto para os

diferentes tipos de mapeamento (urbano e rural), usando imagens de alta resolução espacial.

4.2 CLASSIFICAÇÃO ORIENTADA A OBJETO

Os modelos tradicionais de classificação de imagens recorrem à análise dos valores (níveis digitais) dos *pixels*, nas diferentes bandas espectrais empregadas. Independentemente do classificador adotado, as diferentes respostas espectrais dos *pixels* são, em geral, analisadas em conjunto (ou nas bandas espectrais mais representativas utilizando-se o espaço multidimensional de atributos) (NÓBREGA, 2007).

Para Shackelford e Davis (2003), os esquemas de classificação por *pixel* objetivam identificar a classe de cada *pixel* na imagem, por meio de comparações do vetor n-dimensional de dados de cada elemento com o padrão de cada classe. Estudo do INPE (2010) ressalta que, embora a classificação estatística seja o procedimento convencional mais usado para a análise de imagens, ela apresenta a limitação da análise pontual ser baseada unicamente em atributos espectrais.

Conforme Blaschke et al. (2000), nesta década está ocorrendo uma grande revolução no processamento digital de dados de Sensoriamento Remoto devido às elevadas resoluções espaciais que exigem um novo tipo de processamento além da observação dos *pixels* de forma unitária. O contexto espacial apresenta um modesto papel quando o processo de classificação considera *pixels* individuais. Estudos recentes mostram que esta limitação é bem menor quando o agrupamento de *pixels* vizinhos ou objetos são levados em consideração. O uso de técnicas baseadas em classificação de objetos ao invés de *pixels* se apresenta como alternativas aos métodos convencionais (ANTUNES, 2003).

Segundo Blaschke et al., (2000), dentre os diferentes algoritmos atualmente utilizados em Sensoriamento Remoto, aqueles que permitem a inserção do contexto são os mais promissores em termos de confiabilidade. À medida que o conhecimento extra-espectral é utilizado, melhor é o resultado da classificação, o que leva a uma tendência de inserção de um elemento espacial que agregue informações baseadas em contexto. Para Richards e Jia (1999) o contexto é definido como a relação de um *pixel* com os

pixels da sua vizinhança. Assim, o contexto é um elemento importante no processo de classificação da imagem de alta resolução espacial, porque ele fornece uma maior possibilidade de similaridade espacial e espectral entre os objetos.

Métodos de classificação que consideram a categorização de determinado *pixel* ou objeto, baseado nas características dos *pixels* ou objetos vizinhos são denominados de classificadores contextuais (ANTUNES, 2003).

Desse modo, a segmentação multiresolução e a classificação orientada a objeto fundamentam em contexto permitindo a construção de uma estrutura hierárquica (BISHR, 1997), significando que um objeto pertencente a determinada classe se relaciona com outros objetos de acordo com um grau de hierarquia.

Assim, Antunes (2003) propõe um modelo conceitual da classificação orientada a objeto (Figura 1), no qual expressa o contexto como a união entre o conhecimento *a priori* e a interpretação da imagem.




Figura 1– Modelo conceitual da classificação orientada a objeto.

Fonte: Antunes (2003).

No modelo conceitual da classificação da Figura 1, observa-se que a base do conhecimento se divide entre o conhecimento *a priori* e o da interpretação da imagem, de modo que a imagem passa a constituir os objetos que possibilitam construir uma estrutura semântica em que os descritores são passíveis de associação a regras de lógica *fuzzy*, o que propicia a análise de contexto.

A classificação da imagem baseada em objetos se funda em um fluxo determinado de procedimentos, que se inicia pelo emprego de técnicas de segmentação

para a criação dos objetos e subobjetos. Definidos os objetos, e subobjetos extraem-se, indiretamente dos mesmos, informações espaciais e espectrais. A segmentação da imagem em diferentes escalas num processo de generalização geométrica leva à criação de uma rede hierárquica no, sentido crescente de detalhes a partir de diferentes níveis que relacionam objetos maiores (superobjetos) com objetos menores (subobjetos), em que o conhecimento é inserido. O conhecimento aplicado na classificação orientada a objeto pode ser entendido como uma abordagem que leva em consideração a relação de um objeto com seus objetos vizinhos (ANTUNES, 2003).

Desse modo, as principais premissas que devem ser consideradas na análise orientada a objeto (DEFINIENS, 2003) são:

- A caracterização dos objetos da imagem não pode limitar-se apenas a atributos espectrais, pois estes, muitas vezes não conseguem separar objetos complexos. Por isso, é necessária a utilização de outros atributos como: forma, tamanho, textura, padrão e contexto. Em outras palavras, é necessário inserir o conhecimento do analista no sistema de interpretação da imagem.
- Os objetos de interesse a serem extraídos de uma determinada cena podem estar associados a diferentes níveis de abstração (diferentes escalas) e estes níveis devem estar representados no sistema de análise. Assim, em uma cena de um ambiente intraurbano, existem pequenas residências familiares que se relacionam em nível mais detalhado de escala, e áreas industriais com grandes construções, as quais se relacionam a uma escala mais grosseira.
- A descrição do espaço de atributos de uma determinada classe pode ser imprecisa, o que introduz incertezas na associação de um objeto à determinada classe. Esta incerteza precisa ser modelada, uma vez que ela é parte do resultado da classificação (BENZ et al., 2004).

A materialização dessas premissas é dada pelos procedimentos de segmentação multiresolução e estruturação das classes em rede hierárquica. A segmentação multiresolução é responsável pela geração dos objetos da imagem em diferentes escalas de detalhamento. Na estruturação das classes em rede hierárquica, os objetos e seus relacionamentos são modelados por regras de classificação. Tais regras de classificação podem utilizar funções de pertinência, que modelam a incerteza associada às classes.

4.2.1 Caracterização dos objetos

Os objetos são conceitos, abstrações, definidos em um determinado domínio de uma aplicação (RUMBAUGH et al., 1996). Na abordagem orientada a objeto, a utilização do conceito objeto é peça fundamental na análise de imagens, pois parte-se do princípio de que a informação semântica necessária para a interpretação de uma imagem não está presente no *pixel*, mas sim nos objetos da imagem e nas relações existentes entre eles (DEFINIENS, 2003).

Esses objetos são os segmentos (que têm sua própria especificação espectral e espacial), gerados no processo de segmentação e posteriormente, discriminados e atribuídos às diferentes classes. Eles agrupam dados (atributos) e métodos (comportamento) dentro de sua definição (YOURDON, 1994).

4.2.2 Caracterização de classes

Os objetos com características semelhantes são agrupados em classes, as quais são organizadas em rede hierárquica, onde as classes de um nível inferior (subclasses) herdam as características da classe do nível superior (superclasse). Nesse sistema, os objetos se relacionam por meio da definição da rede hierárquica (herança dos atributos que descrevem a classe) e da rede semântica (estrutura lógica de relação entre as classes).

O reconhecimento de feições em uma imagem pelo cérebro está diretamente ligado à cognição. Ela permite distinguir alguns grupos de feições de maneira genérica implicando relações entre os objetos. O processo cognitivo pode ser executado de forma explícita através da semântica. O conhecimento conduz a rede semântica em que objetos do mundo real são descritos como são percebidos pelo usuário (QUINT, 1997 apud ANTUNES, 2003).

A interpretação da imagem devido à abstração e subjetividade é de difícil automação. Frank e Raubal (1999) salientam que a semântica é a maneira de representar a interpretação da imagem em uma estrutura formal menos subjetiva. O

reconhecimento de objetos na imagem pode ser modelado por meio de suas relações espaciais. No entanto, existe sempre alguma incerteza na representação simplificada do mundo real. O sucesso de interpretação da imagem e a estruturação da semântica dependem a capacidade de generalização que atenda determinado objetivo (GUNST; VOSSelman, 1997).

O resultado da interpretação da imagem próxima ao raciocínio humano parte de um conjunto de objetos ou feições que podem ser organizadas hierarquicamente com seus atributos concretos e suas relações baseadas no conhecimento (ANTUNES, 2003).

A teoria da hierarquia assume que os sistemas, do ponto de vista temporal-espacial, possam ser quase que totalmente decompostos. Para esses fundamentos sistêmicos¹ unitários é usual a designação de “*holon*”, uma palavra criada da originária “*holos*” (em grego: totalidade) e “*on*” (em grego: parte) e que satisfaz à ambivalência de ser o total e ser uma parte. Os “*holons*” estão numa estrutura vertical e horizontal, de modo que podem ser considerados como o produto de uma dupla discretização que se expressa na formação de superfícies. O relacionamento trançado de tais partes integrais na forma de uma árvore esgalhada hierarquizada é conseqüentemente denominado “*holismo*”, expressando especialmente a estrutura em rede vertical/funcional (LANG, 2001).

Na segmentação multiresolução, são criados os diferentes níveis de escala formando uma rede hierárquica de superobjeto, objeto e subobjetos que podem ser analisados de acordo com a lógica de orientação a objeto (que indica as características semânticas dos objetos) em seus aspectos geométricos e temáticos, respectivamente. O primeiro compreende a topologia, forma e posição; o segundo, os atributos não-espaciais dos objetos (KUFONIYI, 1995; JANSENN; MOLENAAR, 1995 apud ANTUNES, 2003).

A segmentação de imagens em multiescalas objetivando um sistema hierarquizado de objetos relacionados entre si apresenta nítidos paralelos de “*Holismo*”. A estrutura hierárquica representa a informação dos dados simultaneamente em diferentes escalas (Figura 2). Os objetos estão em rede de vizinhança e hierarquia, sendo que cada objeto “conhece” os seus objetos vizinhos e subobjetos (MELO 2003).

¹ O **pensamento sistêmico** é um marco conceitual que se desenvolveu nos últimos setenta anos, para que os padrões totais resultem mais claros e possam ser modificados (-Peter Senge. *A quinta disciplina*.xxx: Editorial Granica, 2000).




Figura 2 – Princípio da rede hierárquica em diferentes escalas.

Fonte: Definiens (2003).

A Figura 2 ilustra quatro níveis hierárquicos que relacionam objetos maiores a subobjetos (objetos menores), os quais também “conhecem” os seus vizinhos, gerando uma estrutura lógica de dados.

Bishir (1997) salienta que o contexto é expresso através de definições semânticas dos objetos e suas estruturas descritivas. Isso significa que um objeto relativo a determinada classe se relaciona com outros objetos de acordo com um grau de hierarquia. A classificação baseada nessa estrutura de classes e superclasses, através de uma relação de dependência hierárquica, está subordinada ao conhecimento (GUNST; VOSSELMAN, 1997).

Na Figura 3, há um exemplo de uma rede hierárquica representando classes de vegetação em ambientes intraurbanos a partir da interpretação de uma imagem de resolução espacial alta. Nessa rede hierárquica, os objetos das subclasses Arbórea, Arbustiva e Rasteira herdam o atributo NDVI (*Normalised Difference Vegetation Index*) da superclasse Vegetação (PINHO, 2005).




Figura 3 – Rede hierárquica de tipos de vegetação intraurbana.

Fonte: Pinho (2005).

Na rede hierárquica referida, observam-se somente dois níveis de hierarquia: o nível de vegetação geral e os subobjetos ou níveis de tipos de vegetação em ambientes intraurbanos.

Segundo Hofmann e Reinhardt (2000), as classes podem ser estruturadas em três tipos de redes hierárquicas na abordagem orientada a objetos:

- Hierarquia com hereditariedade: As classes de interesse são agrupadas segundo características comuns, sendo que as subclasses (ou classes filhas) herdam as características das superclasses (ou classes mães). Esse tipo de rede modela o relacionamento entre os atributos físicos entre os objetos (cor, forma, textura; etc.). Um exemplo desse tipo de rede é apresentado na Figura 2, onde as classes Vegetação Arbórea e Rasteira herdam o atributo NDVI alto da sua classe mãe Vegetação.
- Hierarquia de grupos: Este tipo de hierarquia refere-se às relações semânticas entre as classes. Classes com diferentes características físicas, mas com significado semântico coerente, podem ser agrupadas em uma única classe mãe. Um exemplo desse tipo de hierarquia é o agrupamento de diferentes classes de cobertura do solo, que possuem características físicas distintas, em duas classes semânticas: superfícies permeáveis (corpos de água, solo exposto, vegetação) e superfícies impermeáveis (rodovias, estacionamentos e edificações).
- Grupos estruturados: Esse tipo de hierarquia, ao contrário das outras duas, não é utilizado no processo de segmentação. Sua função é agrupar classes de objetos que passarão pelo processo de segmentação baseado em classificação. Neste procedimento, os objetos primitivos oriundos da primeira etapa de classificação têm seus limites modificados, gerando objetos de interesse (BENZ et al., 2004), ou seja, esse tipo de hierarquia é empregado na operação de refinamento dos objetos.

4.2.3 Segmentação

Os métodos de classificação supervisionada e não-supervisionada procuram agrupar os *pixels* de acordo com seu valor do Nível Digital (ND), sendo que cada um pertence a apenas uma categoria, assumindo-se que ele é homogêneo e que seu valor corresponde apenas à categoria na qual foi classificado. Este tipo de classificação digital simplifica a realidade, pois não considera a mistura espacial das características da área, em função da resolução espacial do sensor, além de realizar a classificação somente a partir de características espectrais da imagem (BARNSELEY; BARR, 1996).

Os segmentos (ou regiões) são formados com base num critério de heterogeneidade ou homogeneidade, dependendo do algoritmo. A utilização dessa abordagem que considera regiões faz com que o número de elementos a serem analisados na cena diminua drasticamente, quando é comparado com o procedimento de classificação *pixel-a-pixel*. Trata-se de uma técnica cuja aplicação vem se expandindo em Sensoriamento Remoto, e mesmo em reconhecimento de padrões, de maneira geral (HARALICK; SHAPIRO, 1985; MEINEL; NEUBERT, 2005).

A segmentação consiste, portanto, na subdivisão da imagem em zonas, ou regiões homogêneas e uniformes em função de um determinado atributo da imagem (GONZÁLEZ; WOODS, 2000).

Os algoritmos de segmentação são geralmente baseados em uma das seguintes propriedades básicas de valores digitais: descontinuidade e similaridade. Na primeira categoria, a imagem é segmentada a partir das mudanças bruscas nos níveis de cinza verificadas numa vizinhança local, ou seja, esse tipo de segmentação é utilizado quando se deseja detectar bordas e pontos isolados. A segunda categoria (similaridade) baseia-se em limiarização e crescimento de regiões.

Matematicamente, a operação de limiarização pode ser descrita como uma técnica de processamento de imagens na qual uma imagem de entrada $f(x, y)$ de N níveis de cinza produz uma imagem de saída $g(x, y)$, chamada limiarizada, cuja quantidade de tons de cinza é menor que N . A técnica mais simples de limiarização é a do particionamento do histograma da imagem por um limiar único T .

Seja: $g(x, y) = 1$ se $f(x, y) \geq T$ e $g(x, y) = 0$ se $f(x, y) < T$; em que os *pixels* poderão ser rotulados de 1 ou 0, sendo T um valor de nível de cinza predefinido, ao qual é chamado de limiar (GONZALEZ; WOODS, 2000). A segmentação é realizada,

varrendo a imagem, *pixel a pixel*, e associando-se cada *pixel* a uma determinada classe ou objeto, dependendo do nível de cinza, se for maior ou menor que T . Neste caso considera-se apenas a informação espectral de cada *pixel* para determinar as regiões homogêneas.

Para obter sucesso no processo de segmentação, é necessário definir os elementos a serem classificados na imagem o que depende da escala de trabalho (BLASCHKE et al., 2000).

Um dos algoritmos mais populares para a segmentação pela análise da vizinhança dos pixels é o crescimento de regiões (GONZÁLEZ; WOODS, 2000). González e Woods (2000) sugerem a segmentação por crescimento de regiões, para agrupar os pixels pertencentes a uma determinada classe, se o valor da diferença no nível de intensidade do *pixel* em questão para com o *pixel* vizinho de referência (denominado *pixel* semente) for menor que o valor pré-estabelecido.

O processo de segmentação multiresolução de *Ecognition* utiliza a técnica de crescimento de regiões (processo de segmentação iterativo) que começa com objetos de tamanho de um *pixel* e que, posteriormente são agrupados em objetos maiores, obedecendo a um critério de similaridade ou homogeneidade estabelecido pelo algoritmo utilizado. Em cada etapa, pares adjacentes de objetos na imagem podem ser agrupados, dependendo do nível de homogeneidade entre eles e de o parâmetro de escala, o que produz o crescimento (DEFINIENS, 2009).

4.2.3.1 Segmentação multiresolução

Algoritmos tradicionais de segmentação consideram exclusivamente semelhanças espectrais, independentemente de suas ocorrências locais. As concepções de segmentação partem da hipótese de que elementos de imagem vizinhos pertencem à mesma classe, declaração que é confirmada, ou rejeitada, com base em parâmetros de homogeneidade ou heterogeneidade.

Solberg et al., (1996), enfatizam que na interpretação da imagem a informação contextual é importante. O contexto pode ser definido ao longo de duas dimensões: espectral e espacial. A dimensão espectral se refere às diferentes bandas do

espectro eletromagnético, modelando a correlação espectral, frequentemente melhorando a separação entre as classes. A dimensão espacial é definida pela correlação entre os *pixels* adjacentes e suas vizinhanças, de maneira que o relacionamento de um *pixel* com outras medidas, gera nova informação. (FAN; XIA, 2001).

Ton et al., (1991) apresentam uma alternativa para o melhoramento da qualidade da segmentação baseada no conhecimento semântico² da imagem. Na verdade o conhecimento semântico leva a uma melhora no agrupamento de regiões, mas não contempla necessariamente a homogeneidade (BAATZ; SCHÄPE, 2000).

Baatz e Schäpe (2000) propõem que o primeiro passo de processamento seja a criação de objetos primitivos, cujos objetos ou regiões resultantes seriam a matéria-prima para a classificação e posterior refinamento; por conseguinte, a imagem é segmentada tendo-se em conta o conhecimento *a priori*³, conhecimento o qual leva em conta relações espaciais, como: proximidade, conectividade e orientação.

De acordo com Schneider e Stinwendner, 1999 apud Antunes (2003), os objetos gerados não se restringem às propriedades espectrais, mas também consideram outros aspectos, como textura, tamanho, associação espacial e forma dos objetos que compõem a cena. A forma e o tamanho são elementos importantes para a discriminação de objetos que possuem a mesma resposta espectral. Além dos parâmetros de forma, inerentes aos objetos, a análise da teoria dos fractais pode ser útil à descrição de pequenas variações de forma.

Recentemente, o algoritmo de segmentação multiresolução implementado no *software Ecognition*, tem recebido muitos adeptos na literatura devido a resultados semelhantes aos esperados por fotointérpretes (BLASCHKE et al., 2000; PINHO; FEITOSA; KUX, 2005; BLASCHKE; KUX, 2007).

Na segmentação multiresolução, o critério de homogeneidade é construído a partir do conceito de heterogeneidade interna das regiões. As heterogeneidades são calculadas para os atributos de *cor* e *forma* (que são ponderados pelo tamanho dos objetos).

A soma ponderada (pesos fornecidos pelo usuário) dessas duas heterogeneidades forma o critério de similaridade ou homogeneidade (*f*) (Eq. 4.1), a

² É uma forma de representação do conhecimento definida como um grafo direcionado no qual os vértices representam conceitos, e as arestas representam relações entre os conceitos. <http://www.scielo.br>.

³ É uma expressão filosófica que designa uma etapa para se chegar ao conhecimento, que consiste no pensamento dedutivo (KANT, 2010).

qual é expressa por duas partes: heterogeneidade espectral ou de **cor** ($h_{espectral}$) e heterogeneidade de forma (h_{forma}) (DEFINIENS, 2009):

$$f = w.h_{espectral} + (1 - w). h_{forma} \quad (4.1)$$

Em que:

- f = Critério de homogeneidade
- w = Peso atribuído ao atributo espectral no processo de segmentação, variando de 0 a 1;
- $h_{espectral}$ = Heterogeneidade espectral;
- h_{forma} = Heterogeneidade de forma.

A heterogeneidade espectral ($h_{espectral}$) constitui-se de uma suma ponderada dos desvios-padrão de cada banda para uma determinada região. O peso de cada banda é estabelecido pelo usuário e varia de 0 a 1. A formulação da heterogeneidade espectral é dada pela Eq. 4.2:

$$h_{espectral} = \sum_c w_c \left(n_{Fusão} * \sigma_c^{Fusão} - (n_{Obj1} * \sigma_c^{Obj1} + n_{Obj2} * \sigma_c^{Obj2}) \right) \quad (4.2)$$

Em que:

- σ_c = Desvio-padrão (dos objetos) da resposta espectral na banda c;
- w_c = Peso dado à banda c;
- n = Número de *pixels* do objeto.

A heterogeneidade de forma (h_{forma}) (Eq. 4.3) é composta pela soma ponderada de dois subcritérios: critério de compacidade ($h_{compacidade}$) (Eq. 4.4) e critério de lisura ou suavidade (h_{lisura}) (Eq. 4.6), cujo peso é estabelecido pelo usuário, (Eq. 4.3):

$$h_{forma} = w_{compacidade} * h_{compacidade} + (1 - w_{compacidade}) * h_{lisura} \quad (4.3)$$

$$h_{compacidade} = n_{Fusão} * \frac{l_{Fusão}}{\sqrt{n_{Fusão}}} - \left(n_{Obj1} * \frac{l_{Obj1}}{\sqrt{n_{Obj1}}} + n_{Obj2} * \frac{l_{Obj2}}{\sqrt{n_{Obj2}}} \right) \quad (4.4)$$

O subcritério de compacidade é a razão entre o perímetro e a raiz quadrada do número de *pixels* do objeto, sendo expresso pela Eq. 4.5:

$$Compacidade = \frac{l_{Fusão}}{\sqrt{n_{Fusão}}} \quad (4.5)$$

Em que:

$l_{Fusão}$ = Perímetro do objeto (agrupado);

$n_{Fusão}$ = Tamanho do objeto em número de *pixels* (agrupado).

$$h_{lisura} = n_{Fusão} * \frac{l_{Fusão}}{b_{Fusão}} - \left(n_{Obj1} * \frac{l_{Obj1}}{b_{Obj1}} + n_{Obj2} * \frac{l_{Obj2}}{b_{Obj2}} \right) \quad (4.6)$$

Por sua vez, o subcritério de lisura (ou suavidade) é a razão entre o perímetro e o perímetro da menor caixa possível de enquadrar o objeto, sendo expresso pela Eq. 4.7:

$$Suavidade = \frac{l_{Fusão}}{b_{Fusão}} \quad (4.7)$$

Em que:

$l_{Fusão}$ = Perímetro do objeto (agrupado);

$b_{Fusão}$ = Perímetro do *bouding Box* ou da menor caixa possível de enquadrar o objeto (agrupado).

Analisando-se as equações pode-se dizer que a compactidade é o atributo que representa quão agrupado estão os *pixels* de um determinado objeto, enquanto a lisura ou suavidade representa o grau de irregularidade do contorno de um objeto. Na Figura 4, observa-se o diagrama conceitual da segmentação multiresolução (DEFINIENS, 2009).




Figura 4 – Diagrama conceitual da segmentação multiresolução.

Fonte: Adaptada de Definiens (2009).

O diagrama inicia-se com a unidade mínima de mapeou (MMU), que é o *pixel* para logo determinar quatro critérios de semelhança ou homogeneidade definidos pelo usuário. O maior peso é dado para o critério *Cor*, por ser a imagem multiespectral, o critério *Forma* é compartilhado pelos critérios *Suavidade* e *Compactidade* com seus respectivos valores.

Após do cálculo de critério de homogeneidade (f) (Eq. 4.1), este é comparado com o limiar definido pelo usuário. Se o valor for menor que o quadrado do limiar, os dois objetos são agrupados ou fusionados. Na segmentação multiresolução, o limiar de similaridade é denominado escala, pois como todos os parâmetros empregados na segmentação são ponderados pelos tamanhos dos objetos, o valor de escala influencia no tamanho final destes (PINHO, 2005).

No procedimento de segmentação multiresolução, o usuário precisa definir quatro parâmetros: fator de escala; pesos para cada uma das bandas espectrais; peso para a forma; e peso para a compactidade. Além de sua especificidade em relação à construção do critério de similaridade, a principal característica da segmentação

multiresolução é a possibilidade de segmentar uma mesma imagem em níveis de escala diferenciados que se relacionam entre si, formando uma rede hierárquica de objetos (BAATZ; SCHÄPE, 2000). Dessa forma, cria-se a concepção de superobjeto, objeto e subobjeto. Os primeiros são os objetos localizados em um nível superior, que agregam objetos de um nível inferior. Na rede hierárquica, cada objeto “sabe” a qual superobjeto pertence no nível superior, “reconhece” seus subobjetos no nível inferior e “conhece” seus vizinhos no nível hierárquico onde está contido (BENZ et al., 2004). Esse tipo de informação topológica pode ser utilizada na classificação dos objetos e constitui-se em uma das maiores vantagens apresentadas pela análise de imagens orientada a objetos.

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

Segundo Hofmann e Reinhardt (2000), o contorno dos objetos é influenciado pela estratégia adotada. Assim, quando se inicia a segmentação a partir do nível mais detalhado, o contorno dos superobjetos do nível superior será resultado da soma dos objetos desse nível. Conforme os mesmos autores, a escolha da abordagem de segmentação é uma importante etapa na análise de imagens orientada a objeto.

4.2.4 Classificação dos objetos

Uma vez segmentada a imagem, os objetos ou segmentos produzidos são normalmente representados e descritos por atributos nos quais se fundamenta a classificação. Eles são criados em níveis de informação distintos, na tentativa de envolver tanto os pequenos detalhes presentes na cena quanto às feições maiores, utilizadas posteriormente para apoiar a descrição do contexto. A representação por meio de atributos tem o objetivo de explicar as diferenças essenciais entre os objetos ou entre as classes de objetos (CAMPOS, 2005).

Paralelamente à criação dos objetos ou segmentos, é gerado um banco de dados, no qual são armazenadas as informações calculadas desses segmentos, como

valores de média, máximos e mínimos de brilho, tipos de textura e parâmetros geométricos como forma, área e perímetro (BAATZ et al., 2004 apud NÓBREGA, 2007).

Paralelamente à criação dos objetos ou segmentos, é gerado um banco de dados, no qual são armazenadas as informações calculadas desses segmentos, como valores de média, máximos e mínimos de brilho, tipos de textura e parâmetros geométricos como forma, área e perímetro (BAATZ et al., 2004 apud NÓBREGA, 2007).

Na Tabela 1, são apresentados alguns dos parâmetros baseados nos valores espectrais das bandas da imagem, disponibilizados pelo programa *Ecognition*.

Tabela 1 – Parâmetros baseados em valores espectrais.

Parâmetros	Descrição
Média	Valor médio calculado a partir de todos os pixels em uma determinada banda, dividido pelo somatório dos pixels que forma um segmento.
Desvio padrão	Calculo do desvio padrão dos valores que forma um segmento.
Brilho	Soma do valor médio de todas as bandas espectrais, divididos pelo número de bandas espectrais que formam um segmento.
Razão	A razão de uma banda é o valor médio desta banda, dividido pela soma dos valores médios de todas as bandas espectrais que formam um segmento.
Diferença média entre objetos vizinhos	Para cada objeto vizinho é determinada a diferença média em determinada banda, proporcionalmente ao comprimento limite entre os objetos.

Fonte: Definiens (2009).

A determinação dos parâmetros de forma depende das propriedades geométricas geradas no processo de segmentação (ANTUNES, 2003). Em termos visuais a forma é um dos elementos mais importantes para a interpretação das imagens digitais, sendo uma variável que permite percepção associativa dos objetos da imagem.

Muitos dos parâmetros de forma são baseados na estatística de distribuição espacial dos pixels que compõem um objeto. Na Tabela 2, são apresentados alguns parâmetros baseados na forma.

Tabela 2 – Parâmetros baseados na forma.

Parâmetros	Descrição
Comprimento	Raiz quadrada do produto da área abrangente e a razão entre o comprimento/largura.
Largura	Raiz quadrada da razão entre área abrangente e a razão entre o comprimento/largura.
Comprimento do limite	Somatório dos segmentos limítrofes entre dois objetos.
Área	Numero de pixels contidos no polígono.
Índice de forma	Expressa a suavidade do limite entre objetos. Quanto mais fractal, maior o índice de forma.
Densidade	É descrito pela razão da área que cobre um objeto pelo seu raio.
Assimetria	É determinado de acordo com o semi-eixo maior e o semi-eixo menor de uma elipse que compreende o objeto. Varia de 0 a 1.
Compacidade	É definido pela razão da área do objeto e o raio da circunferência abrangente. Varia de 0 a 1.

Fonte: Definiens (2009).

O método de análise de textura é bastante relevante para a classificação dos objetos, pois explora a características espaciais dos mesmos. Num amplo sentido a textura pode ser vista como a variação do nível de cinza de uma imagem. Alternativamente, textura pode ser interpretada como cópias, simetrias e combinações de vários padrões ou funções locais que exibem determinada variação tonal (ANTUNES, 2003).

Alguns níveis de informação (vetoriais) podem ser introduzidos a fim de delimitar o contexto, tendo em conta que podem condicionar a ocorrência de algumas classes. Quando disponível, a informação de contexto é importante na discriminação de classes espectralmente similares ou com alta variabilidade interna.

A classificação dos objetos constitui-se em uma das maiores vantagens apresentada pela análise de imagens orientada a objeto entendida, no âmbito da imagem, como a análise da relação de um objeto com os seus objetos vizinhos.

A topologia é empregada quando se deseja implementar relações entre os polígonos gerados com base no agrupamentos de *pixels*. Seu objetivo é descrever as propriedades espaciais de áreas de tal maneira que os atributos não-espaciais associados aos elementos ou entidades poligonais possam ser manipulados. Nesse caso, faz-se necessário armazenar informação referente à vizinhança dos objetos (BURROUGH; McDONNELL, 1998).

Consequentemente, o conceito de vizinhança entre objetos ou regiões é definido por meio das relações topologias (BURROUGH; McDONNELL, 1998; MOLENAAR, 1998; MOLENAAR; CHENG, 2000 apud ANTUNES 2003). Definidos os relacionamentos topológicos sobre os objetos, pode-se partir das propriedades de atributos (exemplo: textura, forma, brilho, etc.) e propriedades geométricas (exemplo: área, perímetro, forma), a fim de realizar operações entre objetos. Essas operações produzem como resultado um agrupamento de objetos e valores que satisfazem a determinada restrição espacial (CÂMARA; MEDEIROS, 1998; MOLENAAR, 1998 apud ANTUNES, 2003).

No processo de classificação, o contexto entre os objetos está vinculado à análise de relacionamentos: uma classe “A” só existe se for adjacente a uma classe “C”, ou “A” só existe se estiver contida em “C” (ANTUNES, 2003). Tanto as funções de pertinência *Booleanas* como *fuzzy*, são oriundas das propriedades que compõem os objetos (ou segmentos), propriedades de caráter geométrico e descritivo. Segundo Molenaar e Cheng (2000), o agrupamento de objetos com topologia vetorial permite a determinação de regiões, baseadas em características semânticas.

Para Gorte (1998) e Blaschke et al., (2000), a orientação a objeto conduz o usuário a definir regras complexas baseadas em características espectrais e de relações espaciais. Esse modelo possibilita que a semântica possa ser desenvolvida apoiada em parâmetros físicos e de conhecimento sobre relacionamentos.

A classificação é baseada em níveis hierárquicos dos objetos inter-relacionados. O conhecimento é representado por uma rede semântica, criada a partir de uma estrutura hierárquica. Logo, são usadas funções de pertinência (*fuzzy ou Booleana*)

cujos descritores ou características (espectral, forma e textura) de cada objeto são submetidos para formar os agrupamentos ou classes.

Na Figura 5, são expostos os tipos de descritores que são disponibilizados pelo *software Ecognition*, com o detalhamento do descritor “Características dos Objetos”. Além desses descritores, também é possível a criação de características personalizadas a partir das existentes.




Figura 5 – Descritores em *Ecognition*, exemplo: “Características dos Objetos”.

Fonte: Definiens (2009).

No método de classificação orientado a objeto, a abordagem baseia-se no classificador supervisionado e em funções de pertinência, de modo que o grau de aderência a cada classe especificada é dado para cada objeto. O classificador supervisionado fundamenta-se em objetos (com amostras de treinamento). Já a abordagem da classificação utiliza as funções de pertinência, *fuzzy* ou *Booleana*, em uma técnica que emprega os valores entre 0 e 1, indicando o grau de adesão a uma determinada classe.

Utilizando as funções de pertinência *fuzzy*, um objeto pode estar associado a várias classes com diferentes graus de pertinência. O grau de pertinência varia de “0” (não pertence) a “1” (pertence), a classe considerada é aquela cujo grau de pertinência é maior.

Na Figura 6, observam-se dois tipos de função de pertinência. À esquerda está representada uma função *Booleana* na qual um determinado objeto é classificado como pertencente à classe em questão quando ele tem o valor de atributo maior ou igual

a um número específico. Já à direita, o grau de pertinência é representado por uma aproximação de uma função Gaussiana.




Figura 6 – Tipos de funções de pertinência *Booleana e Fuzzy*.

Fonte: Definiens (2009).

Os conjuntos nebulosos foram desenvolvidos por Lotfi Zadeh (1965) em resposta à dificuldade de fornecer entradas exatas para sistemas inteligentes. A teoria dos conjuntos *fuzzy* (ZADEH, 1978) foi introduzida para lidar com a incerteza em sistemas nebulosos e tem muito em comum com a probabilidade. Em lógica *fuzzy* o nível de compatibilidade de um elemento a um conjunto é denominado grau de pertinência. Para medir graus de pertinência são estabelecidas funções de pertinência.

Na teoria da lógica convencional, a relação de um elemento a um conjunto é bem definida. A função de pertinência de um elemento “ γ ” a um conjunto “ Φ ”, ambos em um universo “ Y ”, é representada por $\mu_{\Phi}(\gamma)$, sendo expresso pela Eq. 4.8:

$$\mu_{\Phi}(\gamma) = \begin{cases} 1, & \text{se e somente se } \gamma \in \Phi \\ 0, & \text{se e somente se } \gamma \notin \Phi \end{cases} \quad (4.8)$$

Nos conjuntos da lógica convencional, um elemento “ γ ” pertence ou não a um conjunto “ Φ ”, ou seja, possui uma função de pertinência bivalente. Zadeh (1965) introduziu a teoria de conjuntos nebulosos com uma idéia mais aberta de pertinência. Nesse caso, a função de pertinência admite valores nebulosos em um intervalo: $\mu_{\Phi}(\gamma) \in [0,1]$, o que pode ser expresso pela Eq. 4.9:

$$\Phi = \{(\gamma, \mu_{\Phi}(\gamma)) \mid \gamma \in Y, \mu_{\Phi}(\gamma): Y \rightarrow [0,1]\} \quad (4.9)$$

Tratando-se de sistemas de classificação, um conjunto *fuzzy* é uma classe de objetos com um grau de pertinência contínuo definido por uma função de pertinência que atribui para cada objeto um grau de pertinência no intervalo [0;1].

Os nomes de conjuntos nebulosos são indicados como valores de variáveis linguísticas. Por exemplo, a distância de um determinado objeto em relação a outro pode ser uma variável linguística assumindo valores perto e longe. Tais valores são descritos por intermédio de conjuntos nebulosos, representados por funções de pertinência, conforme mostrado na Figura7.




Figura 7 – Função de pertinência para a variável linguística distância.
Fonte: Campos (2005).

As funções de pertinência podem ter diferentes formas, dependendo do conceito que se deseja representar e do contexto em que serão empregadas. Funções de pertinência podem ser definidas a partir da experiência e da perspectiva do usuário. Quando se utiliza lógica *fuzzy* (ou lógica nebulosa) em procedimentos de classificação, um mesmo objeto pode estar associado a várias classes ao mesmo tempo com graus distintos de pertinência, o que implica afirmar que o resultado da classificação pode não ser único (LABA et al., 2002). A lógica *fuzzy* pode ser entendida como uma aproximação matemática para quantificar incertezas. A idéia é substituir respostas dicotômicas, estritamente lógicas, por um intervalo contínuo de valores entre 0 e 1, representando a menor ou maior incerteza sobre a classe a ser atribuída.

De forma análoga, os classificadores Bayesianos têm como princípio a discriminação dos elementos baseada na variação da probabilidade (JENSEN, 1996). Lillesand, Kieffer e Chipman (2004), mencionam que a diferença fundamental é que,

enquanto os classificadores Bayesianos utilizam regras de decisão baseadas na variação da probabilidade, para os classificadores *fuzzy* as regras de decisão são baseadas nas variações de incerteza. No entanto, os vetores das médias *fuzzy* e as matrizes de covariância são obtidas através de dados de treinamento, ponderados estatisticamente.

Nesse contexto, modelar a incerteza, em lógica *fuzzy*, corresponde a adaptar a função de pertinência mais adequada à situação em questão. A transição entre a máxima e a mínima incerteza é dada segundo funções matemáticas. Na prática, procura-se utilizar funções “puras” como maneira de simplificar a modelagem da incerteza. Dependendo da função utilizada, a transição entre 0 e 1 pode ser abrupta ou suave, como funções monotônicas, trapezoidais, triangulares e em forma de signo (Gaussianas).

A incerteza é gerada praticamente pela imperfeição da informação na qual se baseia a tomada de decisões, sendo que essa imperfeição pode estar associada a características diferentes da informação, tais como: imprecisão, conflito, ignorância parcial ou total etc. A incerteza que é introduzida durante a classificação de dados de Sensoriamento Remoto pode ser caracterizada por vetores de probabilidade que são produzidos como um subproduto da classificação, disponibilizados pela maioria dos procedimentos de classificação probabilísticos (GOODCHILD; SHI; FISHER, 2002).

Os vetores de probabilidade produzidos na classificação refletem as diferenças da incerteza para a classificação resultante e podem ser considerados indicativos de classificações duvidosas, *pixels* mistos, classes heterogêneas ou de limites ambíguos entre classes (GOODCHILD; SHI; FISHER, 2002). A partir desses vetores de probabilidade, várias medidas de incerteza podem ser estimadas. Um exemplo dessas medidas é a probabilidade máxima indicada no vetor de probabilidade, cujo valor expressa o grau de pertinência para a classe designada e a possível confusão com os demais. Uma probabilidade máxima alta (exemplo: 0,95) deixa poucas dúvidas a respeito da classificação do *pixel*. Já uma probabilidade máxima baixa (exemplo: 0,50) pode indicar atribuição duvidosa a uma determinada classe. A diferença entre a probabilidade máxima e a segunda maior probabilidade para um vetor de atributos pode, então, servir para esclarecer situações de dúvida ao mesmo tempo em que fornece a informação sobre a certeza da classe mais provável (GORTE, 1998).

A classificação *fuzzy* opera com valores de incerteza que ao serem modelados corretamente, fornecem possibilidades (e não probabilidades) de

classificação dos elementos (BAATZ, 2001). Assim, trabalhos como os de Antunes, Lingnau e Da Silva (2003), Blaschke (2003), e outros, modelaram funções de pertinência utilizando, além dos valores médios espectrais extraídos dos objetos, informações contextuais e topológicas (CAMPOS, 2005).

Os classificadores que empregam lógica fuzzy prevêm que um objeto pode estar associado a mais de uma classe com maior ou menor grau de pertinência. Neste caso, é importante avaliar a estabilidade de uma classe observando os diferentes graus de pertinência dos objetos classificados, sendo que as diferenças entre o maior e o segundo maior valor de pertinência podem ser utilizadas para se estimar a estabilidade da classificação. Quanto maior essa diferença, mais estável e confiável é a classificação (BENZ et al., 2004).

No *software Ecognition*, a estabilidade é um recurso que permite explorar as diferenças nos graus de associação entre o melhor e segundo melhor grau de pertinência da classe atribuída de cada objeto, apresentado indícios sobre a ambiguidade da classificação de um objeto. A saída gráfica é visualizada para cada objeto da imagem em uma escala variando do verde-claro (1,0 estabilidade alta) ao vermelho (0,0 estabilidade baixa) (NAVULUR, 2007).

4.3 Análise da confiabilidade da classificação

Avaliar a acurácia⁴ obtida no processo de análise dos dados do Sensoriamento Remoto é uma etapa fundamental, pois os usuários desses produtos necessitam saber sobre a confiabilidade dos dados derivados dos mapas temáticos obtidos por meio dessa ferramenta.

A acurácia de mapas pode ser medida por dois tipos de critérios: acurácia posicional e acurácia temática (ou acurácia da classificação). A acurácia posicional refere-se à quão exata é a localização das feições existentes no mapa em relação à sua verdadeira posição na superfície terrestre. A acurácia temática está relacionada à acurácia das classes temáticas, descritas no mapa com respeito às correspondentes na realidade (CONGALTON; GREEN, 1999).

⁴ Os termos “acurácia” e “exatidão” são considerados sinônimos, sendo utilizados para expressar quão próxima uma observação (ou medida) está do seu valor real (MONICO et al., 2009 apud ANDRADE, 2003).

A forma mais comumente utilizada para verificar a acurácia de um mapa temático está baseada no cálculo de coeficientes estatísticos. Assim, verifica-se até que ponto a classe de informação definida é adequada e quão corretamente está representada no mapa temático (PRADO, 2009).

Os coeficientes estatísticos são gerados pela matriz de confusão (ou matriz de erros) através do cálculo do coeficiente de concordância *Kappa*. Para Rennó et al., (1999), a matriz de confusão serve para avaliar os erros do resultado final da classificação (mapa temático) em relação aos dados de referência (verdade de campo, amostras teste ou mapas temáticos).

No entanto, em processos de classificação apoiados por lógica *fuzzy*, um mesmo elemento pode estar associado a várias classes simultaneamente, com diferentes graus de pertinência, o que pode levar a um resultado não único (LABA et al., 2002). Logo, a acurácia deve ser avaliada em termos de grau de ambiguidade possibilitando a avaliação da incerteza da classificação relacionada às dúvidas surgidas durante o processo de classificação no momento de atribuição do *pixel* ou objeto a uma determinada classe.

4.3.1 Matriz de confusão e coeficiente de concordância *Kappa*

A avaliação da acurácia é o processo usado para estimar a confiabilidade do mapeamento confrontando o resultado da classificação com dados de referência denominados “verdades terrestres”. O objetivo desse processo é a produção da matriz de confusão ou matriz de erros, a partir da qual coeficientes estatísticos podem ser derivados e indicam a acurácia de classes individuais e de todo o mapa (PRADO, 2009).

A matriz de confusão é representada por uma matriz com igual número de colunas e linhas, dado que as colunas representam os dados de referência e, as linhas indicam a classificação gerada a partir dos dados de Sensoriamento Remoto (CONGALTON; GREEN, 1999; LILLESAND; KIEFER; CHIPMAN, 2004). Os elementos da diagonal principal (linha vermelha) indicam o nível de acerto (ou concordância) entre os dois conjuntos de dados e **N** é o número total de amostras coletadas. Uma representação matemática da matriz de confusão é observada na Figura 8.

Linhas (classificação) = i+

Colunas (referência) = +i

	1	2		k	Total da linha X_{i+}
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 8 – Representação matemática da matriz de confusão.
Fonte: Adaptada de Congalton e Green (1999).

Para a geração da matriz de confusão devem ser considerados quatro fatores: (i) os dados de referência; (ii) o tipo de unidade de amostra (ou elemento amostral); (iii) a quantidade de amostras (ou número de elementos amostrais); e (iv) o esquema de amostragem (CAETANO; MATA; FREIRE, 2006).

Os dados de referência devem ter um grau de acurácia mais alto que os dados usados para a geração do mapeamento, podendo incluir: fotografias aéreas; imagens orbitais de melhor resolução espacial que aquela usada na produção do mapa; e levantamento de campo, dados coletados *in situ* (CAETANO; MATA; FREIRE, 2006). Congalton e Green (1999) criticam o uso de mapas temáticos pré-existentes como dados de referência, visto que, raramente, esses mapas foram elaborados a partir do mesmo projeto de classificação.

Unidades de amostra são fragmentos do mapeamento temático que irão compor o conjunto de elementos amostrais. Dentre as opções existentes, tais como único *pixel*, *cluster* (conjunto) de *pixels* (3x3, 5x5 etc), polígono e *cluster* de polígonos, Congalton e Green (1999) afirmam que um *cluster* de *pixels* é convencionalmente preferível, devido a sua identificação mais fácil nos dados de referência e ao fato de permitir delinear melhor a paisagem em relação ao uso do *pixel* individual.

Um número adequado de elementos amostrais por classe deve ser coletado para que a análise realizada seja estatisticamente válida. Para tanto, duas estratégias podem ser usadas no sentido de validar o número de mostras: a distribuição binomial e a multinomial (CAETANO; MATA; FREIRE, 2006). O modelo binomial é apenas apropriado para computar o número de amostras necessário para uma única classe, visto

que este simplesmente faz a distinção entre classificação correta e incorreta e não leva em conta o conjunto de classes analisadas. Por outro lado, na distribuição multinomial o processo de validação não é uma questão apenas de certo ou errado, mas o erro deve ser classificado em relação ao total de possibilidades (ou conjunto de classes), de modo que o uso dessa distribuição implica no conhecimento *a priori* do número de classes e suas proporções no mapa, conforme a Equação 4.10:

$$n = \frac{z^2 pq}{L^2} \quad (4.10)$$

Em que:

n = Tamanho da amostra;

z^2 = Abscissa da curva normal;

p = Porcentagem permissível de acertos;

q = ($q = 1 - p$) porcentagem permissível de erros;

L^2 = Nível permissível de erro.

O tamanho do conjunto amostral também pode ser ajustado com base na importância relativa das classes dentro dos objetivos do projeto de classificação. Algumas vezes é melhor concertar a amostragem nas classes de interesse, aumentando o número de elementos amostrais nessas classes e reduzindo aqueles coletados nas demais classes de menor relevância (CONGALTON; GREEN, 1999).

Além da unidade de amostra e do tamanho do conjunto amostral, a distribuição das amostras tem um importante papel na análise da acurácia. Para assegurar uma conclusão válida sobre a acurácia do mapa, existe a necessidade de que essa distribuição seja feita sem tendência.

Existem cinco esquemas de amostragem usuais, os quais são: amostragem aleatória simples; amostragem sistemática; amostragem aleatória estratificada; amostragem por *cluster* (agregamento); e amostragem sistemática estratificada não-alinhada (CONGALTON; GREEN, 1999). Em uma amostragem aleatória simples, cada unidade na área de estudo tem uma chance igual de ser selecionada, um gerador de números aleatórios é usado para escolher coordenadas (x,y) das amostras. O benefício

da aleatoriedade é que cada unidade na área de estudo tem uma chance igual e independente de ser selecionada, assegurando que não haja tendência. A amostragem aleatória estratificada é similar à amostragem aleatória simples, mas algum conhecimento *a priori* da área de estudo é usado para dividir a área em grupos ou estratos (isto é, classes de cobertura, em mapeamentos temáticos). A maior vantagem, nesse caso, é que todos os estratos, independentemente do tamanho, serão amostrados.

Na amostragem sistemática as unidades de amostra são selecionadas com um intervalo igual sobre a área de estudo. Na maioria dos casos, a primeira amostra é selecionada aleatoriamente e cada amostra sucessiva é adicionada depois com um intervalo específico. A amostragem sistemática estratificada não-alinhada tenta combinar as vantagens da aleatoriedade e estratificação com a facilidade de uma amostragem sistemática. Além disso, o esquema de amostragem por *cluster* tem sido também adotado especialmente para coletar informação de muitas amostras rapidamente, mas esse método deve ser empregado com cautela, evitando formar *clusters* maiores que 10 *pixels*.

Congalton e Green (1999) salientam que a amostragem aleatória simples não garante uma distribuição espacial adequada dos elementos amostrais dentro da área de interesse, porque esta tende a distribuir poucos elementos amostrais para classes pequenas, contudo, que podem ser importantes para o projeto de classificação. Os citados autores destacam igualmente que esquemas de amostragem sistemática, por *cluster* e sistemática estratificada não-alinhada devem ser usados com precaução, visto que tendem a superestimar os elementos amostrais. Assim, muitos analistas preferem a amostragem aleatória estratificada, que combina baixo potencial de tendência (esquema aleatório) com a propriedade de maior cobertura geográfica (estratificação), assegurando que um número mínimo de amostras seja selecionado para cada estrato.

Pela matriz de confusão, é possível calcular algumas medidas descritivas, como a exatidão global (eg), do usuário (eu) e do produtor (ep).

A exatidão global (eg) é a razão entre a soma de todos os elementos classificados corretamente pelo número total de elementos. Essa medida é calculada pela Eq. 4.11:

$$eg = \frac{\sum_{i=l}^r x_{ii}}{N} \quad (4.11)$$

Em que:

eg = Exatidão global;

x_{ii} = Elementos da diagonal principal;

r = Número de classes;

N = Número total de amostras.

O resultado desse índice tende a superestimar o resultado da classificação, uma vez que este considera apenas a proporção de concordância plena, ou seja, as observações classificadas de maneira correta.

A exatidão do usuário (eu) é expressa pela razão do número de elementos classificados corretamente em uma classe pelo número total de elementos classificados na mesma. Essa medida reflete os erros de comissão (e_c) da classificação e indica a probabilidade de um elemento classificado em uma determinada classe realmente pertencer à mesma (LILLESAND; KIEFER; CHIPMAN, 2004). É calculada segundo a Eq. 4.12:

$$eu = \frac{x_{ii}}{x_{i+}} \quad (4.12)$$

Em que:

eu = Exatidão do usuário;

x_{ii} = Número de elementos classificados corretamente;

x_{i+} = Total de elementos classificados para uma categoria 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; KIEFER; CHIPMAN, 2004). Nessa medida reflete os erros de omissão (e_o) da classificação. É calculada segundo a Eq. 4.13:

$$ep = \frac{x_{ii}}{x_{+i}} \quad (4.13)$$

Em que:

ep = Exatidão do produtor;

x_{ii} = Número de elementos classificados corretamente;

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

Outra medida bastante conhecida e também calculada a partir da matriz de confusão é o coeficiente de concordância *Kappa* (ou índice *Kappa*). Para Vieira et al., (1999) o coeficiente é uma medida da concordância real (indicado pelos elementos diagonais da matriz ou pela exatidão global) menos a concordância por chance ou concordância por casualidade (indicado pelo produto total da linha e coluna, que não inclui entradas não reconhecidas), isto é, uma medida do quanto a classificação está de acordo com os dados de referência. Ao contrário da exatidão global, o coeficiente de concordância *kappa* incorpora também os elementos fora da diagonal principal, representando um valor mais confiável. O cálculo do coeficiente de concordância *Kappa* é expresso por (4.14):

$$\hat{K} = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \cdot x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \cdot x_{+i})} \quad (4.14)$$

Em que:

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.

O resultado da estatística *kappa* normalmente é comparado aos valores contidos na Tabela 3, proposta por Landis e Koch (1977), a fim de indicar a qualidade ou desempenho do mapa temático ou da classificação. Embora essa tabela tenha sido desenvolvida para analisar resultados de diagnósticos clínicos, a mesma tem sido

referência para classificar mapas resultantes do emprego de imagens de Sensoriamento Remoto, dentro de certas restrições, e não existe uma fundamentação teórica para recomendar quais são os níveis mínimos aceitáveis desse coeficiente numa classificação (PRADO, 2009).

Tabela 3 – Coeficiente *Kappa* e desempenho da classificação.

Coeficiente <i>Kappa</i>	Desempenho
< 0,00	Péssimo
$0,00 < k \leq 0,20$	Ruim
$0,20 < k \leq 0,40$	Razoável
$0,40 < k \leq 0,60$	Bom
$0,60 < k \leq 0,80$	Muito Bom
$0,80 < k \leq 1,00$	Excelente

Fonte: Adaptada de Landis e Koch (1977).

Outro índice estatístico é o coeficiente de concordância *Kappa* por classe (K) ou coeficiente de concordância para classes, que foi indicado por (ROSENFELD; FITZPATRICK-LINS, 1986), com a finalidade de comparar a exatidão entre duas classes em classificações distintas, sendo expresso pela Eq. 4.15:

$$K = \frac{N_{X_{ii}} - (x_{i+} \cdot x_{+i})}{Nx_{+i} - (x_{i+} \cdot x_{+i})} \quad (4.15)$$

Congalton e Green (1999) relatam que o uso do coeficiente *Kappa* é satisfatório na avaliação da exatidão de uma classificação temática pelo fato de considerar toda a matriz de confusão no seu cálculo, inclusive os elementos fora da diagonal principal, os quais representam as discordâncias na classificação, diferentemente da exatidão global, que usa somente os elementos diagonais (concordância real).

5 MATERIAL E MÉTODO

5.1 Área de estudo

A área selecionada para este estudo localiza-se na cidade de Bogotá D.C., capital do Departamento de Cundinamarca e da Colômbia (Figura 9). Essa região abrange um setor do centro da cidade, o qual apresenta as vias características que contêm os tipos de pavimentos de interesse no presente estudo. A área total da cidade é de 1776 km², com 307 km² de área urbana. As coordenadas do meridiano e paralelo central da cidade são: 74 ° 04' 51,30" de longitude Oeste e 4 ° 35' 56,57" de latitude Norte, respectivamente, sendo que esta é delimitada, ao norte, pelo município de Chia; a leste, pelos municípios da Calera e Choachi; a oeste, pelos municípios de Soacha e Mosquera; e ao sul, pelo Páramo de Sumapáz .




Figura 9 – Localização geral da área de interesse.

A área de estudo considerada para esta pesquisa corresponde a uma superfície aproximada de 72,26 hectares e um perímetro de 3490 m, medido na imagem retificada e delimitada pela linha amarela e preta, conforme representado na Figura 10.




Figura 10 – Localização específica da área de estudo.

A área de estudo compreende os barrios de Paloquemao, Ricaurte, La Pepita, Santa Isabel e Industrial, os quais ficam entre os seguintes endereços: Calle 3^{ra}, Calle 19, Carrera 24 e Carrera 30. As coordenadas da ortoimagem estão referidas ao datum Magna Sirgas, cuja origem está definida no Observatório Astronômico de Bogotá, com as seguintes coordenadas: $4^{\circ} 35' 56,57''$ N e $74^{\circ} 04' 51,30''$ E. Os mapas do I.G.A.C (Instituto Geográfico “Agustín Codazzi”), em escala menor que 1:500.000, utilizam coordenadas planas em metros e não geográficas de latitude/longitude em graus, minutos e segundos, sendo que as coordenadas planas se baseiam em um sistema de projeção cartográfica que representa a superfície esférica da terra projetada sobre um plano. O sistema utilizado na Colômbia é o de Gauss-Krüger.

A Colômbia possui cinco origens para seu sistema de coordenadas planas, separadas entre elas por 3° de longitude. A origem principal ou central é definida pela pilastra do Observatório Astronômico de Bogotá, cujos valores das coordenadas planas são: 100.000 m N e 100.000 m E (falso Norte e falso Leste) para, dessa forma, georreferenciar a ortoimagem de estudo, levando, em conta as coordenadas apresentadas na Tabela 4.


Tabela 4 – Coordenadas planas da ortoimagem - Datum Magna Sirgas.

ESQUINA	E(m)	N(m)	ENDEREÇOS	
1	97.436,90	100.790,20	1-2	Calle 3 ^{ra}
2	98.063,84	100.355,52	3-4	Calle 19
3	99.320,85	102.008,55	2-3	Carrera 24
4	98.794,22	102.450,54	1-4	Carrera 30

Para fazer um melhor aproveitamento dos recursos de *software* e *hardware*, da área de estudo, foi selecionada uma área-teste, a qual é considerada no seguinte item.

5.1.1 Seleção da área-teste

Nessa etapa, foi feito um recorte da área de estudo para o aproveitamento dos recursos de *software* e *hardware*, como: espaço em disco, processador e memória RAM. Além disso, procurou-se um setor da área de estudo sem nuvens e com poucas sombras. Na Figura 11, observa-se a seleção da área-teste.

**Figura 11**– Área-teste.

A área-teste contém as vias que apresentam os tipos de pavimentos para esta pesquisa, bem como os outros tipos de objetos ou classes não consideradas, como as quadras, vegetação, veículos, etc. A área-teste abrange uma superfície aproximada de 16,70 hectares, medida na imagem retificada e delimitada pela linha preta, conforme se explicita na Figura 11 (c).

5.2 Material

Para o desenvolvimento deste projeto de pesquisa, foram empregados os seguintes dados e *softwares*:

- a) Ortoimagem aérea de alta resolução espacial, tomada no ano de 2009, nas bandas referentes à luz azul (390-470 nm), verde (420-580 nm) e vermelha (620-690 nm), fornecida pelo Instituto Geográfico “Agustín Codazzi”. Na Tabela 5, estão algumas especificações dessa ortoreimagem.

Tabela 5 – Especificações da ortoreimagem utilizada na pesquisa.

Dado	Característica
Câmara	Vexcel – UltraCam D
Tipo de sensor	CCD
Tamanho do <i>pixel</i>	9 μ m
GSD (<i>Ground Sample Distance</i>)	0,15 m
Resolução radiométrica	>12 bit
Tipo de arquivo	TIFF,
Tamanho da imagem	4, 008 x 2, 672 <i>pixels</i>

Fonte: gtbibérica⁵ (2009).

O sensor da câmara UltraCam-D (Figura 12) é composto de 8 cones ópticos, distribuídos em paralelo e criando um grande formato de imagem a cores, que, por sua vez, é composto de 13 CCDs. Cada CCD guarda e compacta as formas da imagem final no “cone mestre”, o qual define um sistema de coordenadas simples. Cada CCD é acompanhado de uma dupla componente processamento e armazenamento. 15 unidades para 13 CCDs oferecem uma seguridade na redundância dos dados.

⁵ <http://www.gtbi.net/cms/GTbiWeb/productos/>



Figura 12 – Câmera Vexcel-UltraCam D.
Fonte: gtbibérica⁶ (2009).

- b) Arquivo vetorial das Quadras da área de estudo, elaborado pelo Cadastro Distrital da Bogotá D.C e disponibilizado pelo Instituto Geográfico, em um convênio de cooperação, com a escala de elaboração 1:2000.

Os *softwares* utilizados neste trabalho foram:

- a) *Ecognition* (Trial)⁷ 8.0 e *Ecognition Developer* 8.0: A versão Trial foi usada para testar os processamentos, mas, em seguida, migrou-se para a versão original *Developer* 8.0 e fazer a aplicação em toda a área de estudo. Em geral, com o *software*, pode-se avaliar a segmentação multiresolução, e a classificação.
- b) ENVI 4.4(demo free)⁸ : Aplicado para a geração de Componentes Principais.
- c) ERDAS Imagine 9.1 (demo free)⁹: Utilizado para a digitalização do limite da área de estudo, corte da área-teste e determinação das coordenadas.
- d) ARC-VIEW 3.2 (free)¹⁰: Com a função Spatial Analyst, foi feita a geração dos arquivos *.shp (quadras), para posterior importação no *software Ecognition*.
- e) ArcGis 9.3.1 V. original-Unesp : Elaboração dos mapas temáticos e saída finais.

⁶ <http://www.gtbi.net/cms/GTbiWeb/productos/>

⁷ <http://www.ecognition.com/products/trial-software>

⁸ <http://software.informer.com/getfree-envi-4.4-demo-download/>

⁹ <http://software.informer.com/getfree-erdas-imagine-9.1-download/>

¹⁰ <http://software.informer.com/getfree-arcview-3.2-.exe/>

5.3 Procedimento metodológico

Para atingir o objetivo da pesquisa, ou seja, realizar a classificação dos tipos de pavimentos das vias urbanas empregando análise orientada a objeto foi proposto o procedimento metodológico, ilustrado na Figura 13.




Figura 13 – Procedimento metodológico.

A metodologia apresentada se fundamenta na abordagem orientada a objeto, na qual um problema ou aplicação é representado por uma coleção de objetos que possuem características próprias e interagem entre si (RUMBAUGH et al., 1996). A imagem precisa ser segmentada, para que sejam criados os objetos, os quais passam a ter atributos que permitem construir uma estrutura semântica, cujos descritores são passíveis de associação a regras de lógica *fuzzy*, possibilitando a análise de contexto. Assim, o conhecimento pode ser inserido através das estruturas geométrica e temática dos objetos, baseadas nas suas relações espaciais.

5.3.1 Geração das imagens de componentes principais

A classificação dos tipos de pavimentos das vias urbanas a partir de imagem de alta resolução espacial recorreu a diferentes etapas em sua fase inicial. Essas etapas iniciais cobrem desde a preparação da imagem (composição colorida, recorte), até a uma tentativa de realçar a informação presente nas bandas espectrais, por meio da geração de componentes principais e a própria segmentação que suporte à classificação orientada a objeto.

A alta correlação entre as bandas espectrais originais nas imagens multiespectrais de sensoriamento remoto, decorrente da redundância de informações presentes nas mesmas, usualmente demanda maior esforço computacional e resultados ineficientes nos processos de classificação. O uso da técnica de componentes principais tem o objetivo de atenuar os efeitos dessa correlação, gerando novas imagens (chamadas de componentes principais) que são combinações linearmente independentes produzidas a partir das bandas originais, e que retêm a maior parte da informação contida nas bandas originais em um número menor de bandas (NÓBREGA, 2007).

O processamento foi desenvolvido no programa (*Envi*), gerando as três componentes principais (CP-1, CP-2 e CP-3) a partir das três bandas originais da imagem, conforme mostrado na Figura 14.




Figura 14 – Ilustração das três bandas espectrais RGB e imagens componentes principais.

O uso combinado das componentes e as bandas espectrais da imagem devem permitir uma melhor discriminação dos objetos urbanos. As três componentes principais são responsáveis por quase o 100% de total das informações presentes na imagem multiespectral, minimizando a redundância de informações entre as mesmas, como ocorre nas bandas originais.

5.3.2 Caracterização das classes


A seleção e a caracterização das classes de interesse (tipos de pavimentos das vias urbanas) foram realizadas com base na interpretação visual da ortoimagem identificando as vias pavimentadas (concreto e asfalto); e não pavimentadas (terra). Para a caracterização das classes, foi elaborada uma chave de interpretação, especificando os elementos clássicos empregados no reconhecimento de feições em imagens, tais como: cor, tamanho, forma, localização e textura, além de fotografias de cada local, tomadas durante o trabalho de campo, realizado em 11/01/2010.

Assim, a elaboração da chave de interpretação, os tipos de pavimentos não foram definidos pelas características físico-químicas de seus materiais constituintes, mas pelo padrão que definiram na imagem. Especificamente foram definidos quatro

tipos de classes de pavimentos: Asfalto, Concreto_a, Concreto_b e Terra (via sem pavimento).

No Quadro 1, expõe-se a chave de interpretação elaborada, relacionando as características das classes de interesse.

Quadro 1– Chave de interpretação.

Classe	Amostra da ortoimagem RGB (123)	Cor	Forma, Tamanho, Textura.	Fotografia In loco
Via com pavimento de Concreto_a		Cores cinza claro, tornando-se escuras nas partes de tráfego intenso.	Forma retangular, textura lisa, largura variável.	
Via com pavimento de Concreto_b		Cor cinza claro.	Forma retangular, textura lisa, largura variável.	
Via com pavimento de Asfalto		Cores muito escuras e bem definidas, cinza mais claro nas partes mais antigas.	Forma retangular, textura lisa, largura variável.	
Via de Terra		Cor- avermelhada, clara e escura.	Forma retangular, textura rugosa, largura variável.	

Quadras		Mistura de cores verde, vermelho, azul cinza claro e escuro.	Formas retangulares texturas rugosa e lisa, área variável.	
Outros		Mistura de cores verde, vermelho, cinza claro e escuro.	Formas retangulares e circulares, texturas rugosa e lisa, área variável.	

O Asfalto, em seu contexto, é um produto orgânico composto por hidrocarbonetos pesados, que é utilizado em pavimentação por penetração¹¹. O conceito desse tipo de pavimento é genérico para a classificação levando em conta o Quadro 1 para sua interpretação.

Considerando que o concreto, de forma geral, é uma mistura de um aglomerado (cimento), agregados (areias e britas), água e aditivos, com a finalidade de construção de peças para obras civis¹², sem levar em conta as classes existentes ou descritas em engenharia rodoviária, ficam definidos como:

- **Concreto_a:** Classe de pavimento com tempo de exposição superior a de três anos;
- **Concreto_b:** Classe de pavimento com tempo de exposição inferior a três anos;

A Terra: Associada a uma classe sem revestimento, mais propicia a ocorrência de buracos e outras irregularidades.

¹¹ Universidade Federal Da Paraíba UFPB centro de tecnologia ct departamento de engenharia civil materiais de construção I Prof. Belarmino B. Lira, <http://www.ebah.com.br/asfalto-pdf-a24672.html>, acesso o dia 22 de fevereiro, 2011.

¹² <http://www.cortesiaconcreto.com.br/Manual%20do%20Concreto.pdf>, acesso o dia 22 de fevereiro 2011.

5.3.3 Segmentação

A segmentação multiresolução realizada por meio do método de crescimento de regiões descrito no item 4.2.3.1. A princípio previa-se a necessidade de realizar a segmentação em dois níveis, um que permitiria a extração dos objetos Quadras, e outro, os tipos de pavimentos das vias, entretanto, com a integração do arquivo vetorial de quadras, não foi necessário o segundo nível de segmentação, permanecendo somente um nível.

Estabelecendo-se somente um nível de segmentação, procedeu-se à avaliação dos quatro parâmetros: fator de escala; pesos para cada uma das bandas espectrais; peso para a forma; e peso para a compacidade. Nessa etapa, teve-se em conta a literatura consultada, Blaschke e Kux (2007), além daqueles referidos no local pertinente, relativos aos trabalhos que empregam segmentação e análise orientada a objeto, com imagens de resolução espacial alta e muito alta. Essa consulta não foi muito favorável, pelo fato de esses trabalhos terem utilizado a maior resolução espacial de 1 m no terreno, enquanto a imagem desta pesquisa tem 0,15 m de resolução espacial no terreno.

Assim como é mostrado nos Quadros 2, 3, e 4, fizeram-se mais de 100 testes com variação de escala, variação de compacidade e variação de forma, sendo que o parâmetro que não foi alterado foi o peso dos dados de entrada. A princípio trabalho-se com as três bandas espectrais e, os três componentes principais em seguida foram processados usando as três bandas espectrais. Na Figura 15, mostra-se um exemplo de uma segmentação usando o arquivo vetorial quadras.







Figura 15 – Exemplo de uma segmentação com o arquivo vetorial.

Quadro 2–Teste de segmentação escala 10, 20, 30; forma 0,1; 0,6; 0,5 e compacidade 0,5; 0,8; 0,7.

Ajustes de segmentação		Composição do critério de homogeneidade					
Peso das bandas multiespectrais e componentes principais.	1, 1, 1 1, 1, 1						
Escala	10	Forma 0,1	Compa* 0,5	Forma 0,6	Compa 0,8	Forma 0,5	Compa 0,7
Ajustes de segmentação		Composição do critério de homogeneidade					
Peso das bandas multiespectrais e componentes principais	1, 1, 1 1, 1, 1						
Escala	20	Forma 0,1	Compa* 0,5	Forma 0,6	Compa 0,8	Forma 0,5	Compa 0,7
Ajustes de segmentação		Composição do critério de homogeneidade					
Peso das bandas multiespectrais e componentes principais	1, 1, 1 1, 1, 1						
Escala	30	Forma 0,1	Compa* 0,5	Forma 0,6	Compa 0,8	Forma 0,5	Compa 0,7





Compa*= Compacidade

Quadro 3 – Teste de segmentação escala 10, 20, 30; forma 0,5; 0,8; 0,7 e compacidade 0,1; 0,6; 0,5.

Ajustes de segmentação		Composição do critério de homogeneidade					
Peso das bandas multiespectrais e componentes principais	1, 1, 1 1, 1, 1						
		Forma 0,5	Compa* 0,1	Forma 0,8	Compa 0,6	Forma 0,7	Compa 0,5
Ajustes de segmentação		Composição do critério de homogeneidade					
Peso das bandas multiespectrais e componentes principais	1, 1, 1 1, 1, 1						
		Forma 0,5	Compa* 0,1	Forma 0,8	Compa 0,6	Forma 0,7	Compa 0,5
Ajustes de segmentação		Composição do critério de homogeneidade					
Peso das bandas multiespectrais e componentes principais	1, 1, 1 1, 1, 1						
		Forma 0,5	Compa* 0,1	Forma 0,8	Compa 0,6	Forma 0,7	Compa 0,5

Compa*= Compacidade

Quadro 4 – Teste de segmentação escala 40, 50, 60; forma 0,1; 0,6; 0,5 e compacidade 0,5; 0,8; 0,7.

Ajustes de segmentação		Composição do critério de homogeneidade					
Peso das bandas multiespectrais e componentes principais	1, 1, 1 1, 1, 1						
Escala	40	Forma 0,1	Compa* 0,5	Forma 0,6	Compa 0,8	Forma 0,5	Compa 0,7
Ajustes de segmentação		Composição do critério de homogeneidade					
Peso das bandas multiespectrais e componentes principais	1, 1, 1 1, 1, 1						
Escala	50	Forma 0,1	Compa 0,5	Forma 0,6	Compa 0,8	Forma 0,5	Compa 0,7
Ajustes de segmentação		Composição do critério de homogeneidade					
Peso das bandas multiespectrais e componentes principais	1, 1, 1 1, 1, 1						
Escala	60	Forma 0,1	Compa 0,5	Forma 0,6	Compa 0,8	Forma 0,5	Compa 0,7

Compa*= Compacidade

Com base nos testes anteriores, foram selecionados os parâmetros usados na segmentação, tanto para área-teste como para área de estudo, efetuando-se depois o isolamento dos polígonos das vias com as quadras (praticamente as quadras delimitam as vias), fazendo um *merge* (união) desses polígonos dentro das quadras para posteriormente ajustar os perímetros das mesmas aos limites ou bordas das vias, mediante um *buffer*, conforme é mostrado na Figura 16.




Figura 16 – Segmentação da ortoimagem (a), união dos polígonos dentro das quadras (b), e *Buffer* dos perímetros das quadras.

Observa-se, na Figura 16 (a), a segmentação da ortoimagem com os vetores quadras ou arquivo vetorial quadras. Já na Figura 16 (b), foi feito o *merge* ou união dos polígonos dentro das quadras para determinar a delimitação dos polígonos das vias a classificar, ao passo que, na Figura 16 (c), observa-se a geração do *buffer*, de aproximadamente 3 m separando a parte pedestre e criando um isolamento das vias.

5.3.4 Definição das classes de informação

O uso da segmentação multiresolução propiciado uma separação hierárquica das classes, através do relacionamento entre subobjetos e superobjetos. Não obstante, nesta pesquisa foi empregado somente um nível de segmentação, à medida que a realização de uma classificação contextual (usando a delimitação das quadras) foi suficiente para discriminar as vias no ambiente urbano. Portanto, a metodologia utilizada não utiliza a hierarquia entre objetos de diferentes níveis de segmentação, mas sim o relacionamento contextual dos objetos presentes no cenário da imagem.

Assim sendo, foram estruturadas as classes de interesse. A elaboração dessa estrutura levou em conta os atributos da chave de interpretação (Quadro 1), tendo sido definidas seis classes (Asfalto, Concreto_a, Concreto_b, Terra, Quadras, e Outros). Na classe Outros, foram incluídas as feições associadas a carros, sombras, manchas de óleo

na via, vegetação, estruturas, pontes, etc., ou seja, quaisquer tipos de alvos que não se enquadrem nas outras classes conforme se verifica na Figura 17.



Figura 17 – Classes de interesse.

Na definição das classes, nota-se que as Quadras constituem uma classe muito importante pela determinação da definição física das vias, enquanto, na saída dos mapas temáticos Quadras passam a ser mais uma classe de Outros.

5.3.5 Definição de atributos e regras de pertinência

Para a realização da classificação com o *software Ecognition*, são necessárias outras três etapas: conhecimento das características dos objetos ou atributos inerentes aos objetos; aplicação da lógica *Fuzzy* ou *Booleana*; e utilização dos operadores lógicos, procurando comparar e analisar um ou todos os objetos a serem classificados. Dessa forma, o principal propósito dessa etapa foi a seleção e a identificação dos atributos mais relevantes, isto é, aqueles que apresentam alta correlação com as classes e baixa correlação com outros atributos.

Foram usados atributos baseados em parâmetros espectrais para cada uma das classes geradas a partir das bandas 1, 2 e 3 correspondentes aos valores médios espectrais dos *Layers* 1,2 e 3, e dos componentes principais 4,5 e 6 correspondentes aos valores médios dos *Layers* 4, 5 e 6, além do valor médio do brilho das bandas espectrais. Posteriormente determinou-se os valores das funções *Fuzzy* ou *Booleanas*, para cada classe os quais são apresentados a em seguida:

Para Asfalto: No Quadro 5, são expostos os descritores e funções de pertinência aplicados para a classe Asfalto, assim como os tipos de funções aplicadas com seu respectivo parâmetro, ao final do Quadro, coloca-se um exemplo de um dos segmentos classificados, com sua função. Dentro dos descritores, levou-se em conta, neste caso, a classificação por área como negação da mesma. Este descritor é um aplicativo do *software Ecognition* que funciona como a negação do calculo da área (numero de *pixels*) do um polígono mediante a aplicação da função *Booleana* num rango determinado como é mostrado na Figura 18.









Figura 18 – Função booleana da área.

Quadro 5 – Descritores e funções de pertinência para a classe Asfalto.

Descritores de forma e espectral	Funções de pertinência aplicadas	Especificação da função e parâmetros
		
Name Asfalto		
Segmento amostrado de Asfalto	Função de pertinência Banda 3	
		

Para Concreto_a: No Quadro 6, os descritores e funções de pertinência aplicados para a classe Concreto_a, bem como os tipos de funções aplicadas com seu respectivo parâmetro;; ao final do Quadro, coloca-se um exemplo de um dos segmentos classificados, com sua função. Dentro dos descritores, levaram-se em consideração neste caso, as expressões lógicas *or* (ou); *and* (e).





Quadro 6 – Descritores e funções de pertinência para a classe Concreto_a.



Para Concreto_b: No Quadro 7, são apresentados os descritores e funções de pertinência aplicados para a classe Concreto_b, assim como os tipos de funções aplicadas com seu respectivo parâmetro;; ao final do Quadro, coloca-se um exemplo de




um dos segmentos classificados com sua função. Dentro dos descritores, tiveram-se em conta, neste caso, todas as 6 bandas, além da função média de brilho.

Quadro 7 – Descritores e funções de pertinência para a classe Concreto_b.

Descritores de forma e espectral	Funções de pertinência aplicadas	Especialização da função e parâmetros
		
Segmento mostrado de Concreto_b	Função de pertinência Banda 3	
		

Para Terra: No Quadro 8, estão os descritores e funções de pertinência aplicados para a classe Terra, bem como os tipos de funções aplicadas, com seu respectivo parâmetro; ao final, coloca-se um exemplo de um dos segmentos classificados com sua função. Dentro dos descritores, levaram-se em conta, neste caso, 3 bandas, além da função média de brilho.






Quadro 8 – Descritores e funções de pertinência para a classe Terra.

Descritores de forma e espectral	Funções de pertinência aplicadas	Especializaçã o da função e parâmetros
		
Segmento amostrado de Terra	Função de pertinência Banda 3	
		

Para Quadras: No Quadro 9, mostram-se os descritores e funções de pertinência aplicados para a classe Quadras, além dos tipos de funções aplicadas com seu respectivo parâmetro; ao final do Quadro, vem um exemplo de um dos segmentos


classificados com sua função. O descritor espacial (exemplo.: área pelo número de *pixels*) foi utilizado para a classificação, visto que persistia a existência de mistura entre a resposta espectral com as classes Concreto e Terra.

Quadro 9 – Descritores e funções de pertinência para a classe Quadras.

Descritores de forma e espectral	Funções de pertinência aplicadas	Especialização da função e parâmetros
		
		
Segmento amostrado de Quadra	Descritores de forma	
		

O software *Ecognition* fornece um quadro denominado Informação dos Objetos na Imagem (*Image Object Information*), onde constam as informações das características do objeto selecionado, seus valores espectrais e seu relacionamento com os objetos vizinhos. Um exemplo é mostrado no Quadro 10.

Quadro 10 – Informação dos objetos na imagem.

Segmentos amostrados	Informação dos Objetos na Imagem																																																																	
Asfalto		<table><thead><tr><th></th><th>Value</th></tr></thead><tbody><tr><td colspan="2">Current Classificati...</td></tr><tr><td>Asfalto</td><td>0.937</td></tr><tr><td>none</td><td></td></tr><tr><td colspan="2">Alternative Assign... Value</td></tr><tr><td>Asfalto</td><td>0.937</td></tr><tr><td>Doutros</td><td>0.007</td></tr><tr><td>Concreto_b</td><td>0.000</td></tr><tr><td>Concreto</td><td>0.000</td></tr><tr><td>Estruturas_pontes</td><td>0.000</td></tr><tr><td>Fundo</td><td>0.000</td></tr><tr><td>Concreto_a</td><td>0.000</td></tr><tr><td>Carros</td><td>0.000</td></tr><tr><td>Quadras</td><td>0.000</td></tr><tr><td>Terra</td><td>0.000</td></tr></tbody></table>		Value	Current Classificati...		Asfalto	0.937	none		Alternative Assign... Value		Asfalto	0.937	Doutros	0.007	Concreto_b	0.000	Concreto	0.000	Estruturas_pontes	0.000	Fundo	0.000	Concreto_a	0.000	Carros	0.000	Quadras	0.000	Terra	0.000	<table><thead><tr><th>Term</th><th>Feature Value</th><th>Value</th></tr></thead><tbody><tr><td colspan="3">Evaluation of... 0.937</td></tr><tr><td colspan="3">and (min)</td></tr><tr><td>Brightness</td><td>53.82</td><td>0.966</td></tr><tr><td>Mean Layer 1</td><td>52.01</td><td>0.937</td></tr><tr><td>Mean Layer 2</td><td>54.47</td><td>0.949</td></tr><tr><td>Mean Layer 3</td><td>54.98</td><td>0.952</td></tr><tr><td>Mean Layer 4</td><td>12.16</td><td>0.984</td></tr><tr><td>not Area</td><td>3190 Pxl</td><td>1.000</td></tr></tbody></table>	Term	Feature Value	Value	Evaluation of... 0.937			and (min)			Brightness	53.82	0.966	Mean Layer 1	52.01	0.937	Mean Layer 2	54.47	0.949	Mean Layer 3	54.98	0.952	Mean Layer 4	12.16	0.984	not Area	3190 Pxl	1.000						
	Value																																																																	
Current Classificati...																																																																		
Asfalto	0.937																																																																	
none																																																																		
Alternative Assign... Value																																																																		
Asfalto	0.937																																																																	
Doutros	0.007																																																																	
Concreto_b	0.000																																																																	
Concreto	0.000																																																																	
Estruturas_pontes	0.000																																																																	
Fundo	0.000																																																																	
Concreto_a	0.000																																																																	
Carros	0.000																																																																	
Quadras	0.000																																																																	
Terra	0.000																																																																	
Term	Feature Value	Value																																																																
Evaluation of... 0.937																																																																		
and (min)																																																																		
Brightness	53.82	0.966																																																																
Mean Layer 1	52.01	0.937																																																																
Mean Layer 2	54.47	0.949																																																																
Mean Layer 3	54.98	0.952																																																																
Mean Layer 4	12.16	0.984																																																																
not Area	3190 Pxl	1.000																																																																
Concreto_a		<table><thead><tr><th></th><th>Value</th></tr></thead><tbody><tr><td colspan="2">Current Classificati...</td></tr><tr><td>Concreto_a</td><td>0.648</td></tr><tr><td>none</td><td></td></tr><tr><td colspan="2">Alternative Assign... Value</td></tr><tr><td>Concreto_a</td><td>0.648</td></tr><tr><td>Carros</td><td>0.000</td></tr><tr><td>Asfalto</td><td>0.000</td></tr><tr><td>Concreto_b</td><td>0.000</td></tr><tr><td>Concreto</td><td>0.000</td></tr><tr><td>Estruturas_pontes</td><td>0.000</td></tr><tr><td>Fundo</td><td>0.000</td></tr><tr><td>Doutros</td><td>0.000</td></tr><tr><td>Quadras</td><td>0.000</td></tr><tr><td>Terra</td><td>0.000</td></tr></tbody></table>		Value	Current Classificati...		Concreto_a	0.648	none		Alternative Assign... Value		Concreto_a	0.648	Carros	0.000	Asfalto	0.000	Concreto_b	0.000	Concreto	0.000	Estruturas_pontes	0.000	Fundo	0.000	Doutros	0.000	Quadras	0.000	Terra	0.000	<table><thead><tr><th>Term</th><th>Feature Value</th><th>Value</th></tr></thead><tbody><tr><td colspan="3">Evaluation of... 0.648</td></tr><tr><td colspan="3">or (max)</td></tr><tr><td>Mean Layer 3 [...]</td><td>82.98</td><td>0.616</td></tr><tr><td colspan="3">and (min)</td></tr><tr><td>Mean Layer 6</td><td>0.0434177168</td><td>0.999</td></tr><tr><td>Mean Layer 3</td><td>82.98</td><td>0.648</td></tr><tr><td>Mean Layer 2</td><td>91.17</td><td>0.697</td></tr><tr><td colspan="3">and (min)</td></tr><tr><td>Mean Layer 1</td><td>93.45</td><td>0.437</td></tr><tr><td>Brightness</td><td>89.2</td><td>0.982</td></tr></tbody></table>	Term	Feature Value	Value	Evaluation of... 0.648			or (max)			Mean Layer 3 [...]	82.98	0.616	and (min)			Mean Layer 6	0.0434177168	0.999	Mean Layer 3	82.98	0.648	Mean Layer 2	91.17	0.697	and (min)			Mean Layer 1	93.45	0.437	Brightness	89.2	0.982
	Value																																																																	
Current Classificati...																																																																		
Concreto_a	0.648																																																																	
none																																																																		
Alternative Assign... Value																																																																		
Concreto_a	0.648																																																																	
Carros	0.000																																																																	
Asfalto	0.000																																																																	
Concreto_b	0.000																																																																	
Concreto	0.000																																																																	
Estruturas_pontes	0.000																																																																	
Fundo	0.000																																																																	
Doutros	0.000																																																																	
Quadras	0.000																																																																	
Terra	0.000																																																																	
Term	Feature Value	Value																																																																
Evaluation of... 0.648																																																																		
or (max)																																																																		
Mean Layer 3 [...]	82.98	0.616																																																																
and (min)																																																																		
Mean Layer 6	0.0434177168	0.999																																																																
Mean Layer 3	82.98	0.648																																																																
Mean Layer 2	91.17	0.697																																																																
and (min)																																																																		
Mean Layer 1	93.45	0.437																																																																
Brightness	89.2	0.982																																																																
Concreto_b		<table><thead><tr><th></th><th>Value</th></tr></thead><tbody><tr><td colspan="2">Current Classificati...</td></tr><tr><td>Concreto_b</td><td>0.487</td></tr><tr><td>none</td><td></td></tr><tr><td colspan="2">Alternative Assign... Value</td></tr><tr><td>Terra</td><td>0.950</td></tr><tr><td>Concreto_b</td><td>0.487</td></tr><tr><td>Concreto_a</td><td>0.000</td></tr><tr><td>Carros</td><td>0.000</td></tr><tr><td>Concreto</td><td>0.000</td></tr><tr><td>Estruturas_pontes</td><td>0.000</td></tr><tr><td>Fundo</td><td>0.000</td></tr><tr><td>Doutros</td><td>0.000</td></tr><tr><td>Quadras</td><td>0.000</td></tr><tr><td>Asfalto</td><td>0.000</td></tr></tbody></table>		Value	Current Classificati...		Concreto_b	0.487	none		Alternative Assign... Value		Terra	0.950	Concreto_b	0.487	Concreto_a	0.000	Carros	0.000	Concreto	0.000	Estruturas_pontes	0.000	Fundo	0.000	Doutros	0.000	Quadras	0.000	Asfalto	0.000	<table><thead><tr><th>Term</th><th>Feature Value</th><th>Value</th></tr></thead><tbody><tr><td colspan="3">Evaluation of... 0.487</td></tr><tr><td colspan="3">and (min)</td></tr><tr><td>Brightness</td><td>140.01</td><td>0.487</td></tr><tr><td>Mean Layer 1</td><td>147.1</td><td>0.997</td></tr><tr><td>Mean Layer 2</td><td>143.12</td><td>0.912</td></tr><tr><td>Mean Layer 3</td><td>129.81</td><td>0.928</td></tr><tr><td>Mean Layer 4</td><td>162.23</td><td>0.553</td></tr><tr><td>Mean Layer 5</td><td>0.120254427</td><td>0.981</td></tr><tr><td>Mean Layer 6</td><td>0.315170766</td><td>0.986</td></tr></tbody></table>	Term	Feature Value	Value	Evaluation of... 0.487			and (min)			Brightness	140.01	0.487	Mean Layer 1	147.1	0.997	Mean Layer 2	143.12	0.912	Mean Layer 3	129.81	0.928	Mean Layer 4	162.23	0.553	Mean Layer 5	0.120254427	0.981	Mean Layer 6	0.315170766	0.986			
	Value																																																																	
Current Classificati...																																																																		
Concreto_b	0.487																																																																	
none																																																																		
Alternative Assign... Value																																																																		
Terra	0.950																																																																	
Concreto_b	0.487																																																																	
Concreto_a	0.000																																																																	
Carros	0.000																																																																	
Concreto	0.000																																																																	
Estruturas_pontes	0.000																																																																	
Fundo	0.000																																																																	
Doutros	0.000																																																																	
Quadras	0.000																																																																	
Asfalto	0.000																																																																	
Term	Feature Value	Value																																																																
Evaluation of... 0.487																																																																		
and (min)																																																																		
Brightness	140.01	0.487																																																																
Mean Layer 1	147.1	0.997																																																																
Mean Layer 2	143.12	0.912																																																																
Mean Layer 3	129.81	0.928																																																																
Mean Layer 4	162.23	0.553																																																																
Mean Layer 5	0.120254427	0.981																																																																
Mean Layer 6	0.315170766	0.986																																																																

Terra

	Value
Current Classificati...	
Terra	0.655
none	
Alternative Assign... Value	
Terra	0.593
Carros	0.000
Concreto_a	0.000
Concreto_b	0.000
Concreto	0.000
Estruturas_pontes	0.000
Fundo	0.000
Outros	0.000
Quadras	0.000
Asfalto	0.000

Term	Feature Value	Value
Evaluation of...		0.655
and (min)		0.655
Brightness	144.02	0.655
Mean Layer 1	161.31	0.994
Mean Layer 2	145.14	0.997
Mean Layer 3	125.61	0.984

Quadras

	Value
Current Classificati...	
Quadras	1.000
none	
Alternative Assign... Value	
Quadras	1.000
Concreto_a	0.962
Carros	0.000
Concreto_b	0.000
Concreto	0.000
Estruturas_pontes	0.000
Fundo	0.000
Outros	0.000
Asfalto	0.000
Terra	0.000

Term	Feature Value	Value
Evaluation of...		1.000
and (min)		1.000
Area >= 32000...	122285 Pxl	1.000
not Length	493.02 Pxl	1.000

Outros

	Value
Current Classificati...	
Outros	0.759
none	
Alternative Assign... Value	
Outros	0.759
Concreto_a	0.000
Concreto_b	0.000
Concreto	0.000
Estruturas_pontes	0.000
Fundo	0.000
Carros	0.000
Asfalto	0.000
Quadras	0.000
Terra	0.000

Term	Feature Value	Value
Evaluation of...		0.759
and (min)		0.759
Mean Layer 5	0.959275032	1.000
Mean Layer 3	17.76	0.759
Mean Layer 2	16.32	0.926
Mean Layer 1	22.02	0.956
Brightness	18.7	0.938

Com essas informações, percebe-se que: O segmento amostrado de Asfalto teve um valor (*Value*) alto, dado pelas funções *fuzzy* de 0,937; observa-se que a classe mais próxima dessa classificação foi a classe Outros, com um valor (*Value*) de 0,007. O Concreto_a, com um valor de 0,648, dado pelas funções *fuzzy* não teve nenhuma outra classe como alternativa na classificação, apesar de esse valor não ser muito alto. O Concreto_b, classificado com um valor de 0,487, dado pelas funções *fuzzy*, é um valor

baixo, comparado com o valor de 0,950, dado para a classe alternativa Terra, mas foi bem classificado pelas regras estabelecidas previamente para essa classificação. Para a classe Terra, o valor de 0,655, como os demais valores, é categorizado pelos valores das bandas consideradas para a classificação desses objetos, de modo que o valor de 0,593, na primeira tabela, é reforçado pelos valores das Bandas 1, 2, e 3, estabelecendo finalmente o valor, mediante as funções *fuzzy*, de 0,655, sem outra classe alternativa. Já para a classe Quadras, pela regra estabelecida da área, obteve-se um valor de 1,0 com uma classe alternativa de Concreto_a, com um valor de 0,962, mas o descritor da área predominou tornando válida a regra. Finalmente, na classe Outros foram agrupados os demais objetos não fundamentais para esta pesquisa, tratando-se de estabelecer os parâmetros espectrais e espaciais para cada um; neste caso um possível óleo no chão foi classificado com um valor de 0,759, dado pelas funções *fuzzy* sem outra classe alternativa. Assim, foram indicadas as 6 classes, procurando-se classificá-las de acordo com as características mencionadas anteriormente.

5.3.6 Classificação

Para a classificação, foram empregados os descritores baseados em parâmetros espectrais e de forma, de acordo com as expressões dos Quadros 5 a 9. Primeiramente, aplicou-se a classificação à área-teste para, posteriormente, aplicar em toda a área de estudo.

No procedimento de classificação “*Fuzzy*” utilizado, é definida cada classe de interesse. Para inserir esse conhecimento dos objetos, dois fatores devem ser levados em consideração: os descritores utilizados para diferenciar cada classe e o tipo de regra de decisão adotada para cada classe.

Os descritores utilizados na diferenciação entre as classes foram: basicamente os espectrais, os quais fornecem informações dos valores de brilho das bandas e do relacionamento com descritores espectrais de vizinhança. Foram usados o Brilho (*Brightness*) que corresponde à soma dos valores de brilho das três bandas espectrais, dividido pelo número de bandas a Média (*Mean*) de cada uma das bandas definida como: o valor médio, calculado a partir de todos os *pixels* de uma determinada banda

dividido pelo somatório dos *pixels* que formam um segmento. Desse modo, correspondem:

- *Mean Layer* 1 para a Banda 1;
- *Mean Layer* 2 para a Banda 2 e
- *Mean Layer* 3 para a Banda 3.

As imagens componentes principais foram definidas com seus valores médios, da seguinte maneira:

- *Mean Layer* 4 para o componente principal 1;
- *Mean Layer* 5 para o componente principal 2 e
- *Mean Layer* 6 para o componente principal 3.

Os descritores de forma subdividem-se em valores de área, perímetro, largura etc.; o descritor de área usado foi definido pelo número de *pixels* contidos no polígono pela unidade de medida do *pixel*. A área foi utilizada para as classes e o parâmetro foi definido de acordo com suas próprias características, fornecendo apoio à separação de classes.

No processo da classificação, o contexto entre os objetos está vinculado à análise de relacionamentos. Tanto as regras Booleanas como as funções de pertinência são oriundas das propriedades geométricas e descritivas que compõem os objetos.



Tal como na teoria dos conjuntos Booleanos, os conjuntos fuzzy podem ser combinados por meio de diferentes operações: união (maximização), intersecção (minimização) e negação (complemento) com vistas à classificação (AZEVEDO et al., 2001).

Quando se trabalha com regras de decisão, podem-se utilizar combinações desses operadores. Nesses casos a complexidade da classificação aumenta.

A função de pertinência de um objeto a uma determinada classe, como mostrado no Quadro 11, é especificada por:

- Operador lógico;
- A própria função, e
- Descritores dos objetos.

Quadro 11 – Especificação da função de pertinência.

Classe	Operador lógico	Descritor	Função	Intervalo
Concreto_a		 Mean Layer 2		5 a 138

A formulação das regras fuzzy, apoiadas nesses diferentes descritores dos objetos, permite a realização da semântica dos objetos ou regiões, consequentemente, possibilita uma classificação interativa e próxima à realidade (QUINT, 1997 apud ANTUNES, 2003).

5.3.7 Avaliação da classificação

Nesta etapa, foram utilizadas duas técnicas de avaliação: a matriz de confusão, através do cálculo de coeficientes estatísticos, e a análise de medidas de incerteza, a partir das estatísticas de estabilidade da classificação fornecidas pelo o *software Ecognition*.

Convencionalmente, para avaliar a acurácia de uma classificação, é usada a matriz de confusão ou matriz de erros, a qual compara dados de referência ou “verdade terrestre” com o resultado do mapeamento, sendo essa uma das estratégias adotadas nesta pesquisa. A realização dessa análise pressupõe, inicialmente, a definição de alguns parâmetros, tais como: esquema de amostragem; número de elementos amostrais; tipo de unidade amostral; e dados de referência.

Nessa aplicação, optou-se por utilizar o esquema de amostragem aleatório estratificado por classe, que combina a distribuição geográfica com o menor potencial de tendência. Essa estratégia de amostragem é particularmente útil, por garantir que todas as classes de estudo ou de interesse sejam amostradas.

Para estimar o número de elementos amostrais numa imagem classificada, onde a variável não é quantitativa, mas categórica, recomenda-se usar a probabilidade binomial (CHUVIECO, 2002). A expressão mais simples, sem considerar a correção de população finita, usou Equação 4.10 com um nível de probabilidade de 95% de confiança, um nível permissível de erro de $\pm 5\%$, e 85% de acertos. Assim, foi obtido que:

$$n = \frac{1,96^2 \cdot 85,15}{5^2} = 195,92$$

Esse valor indica que, ao menos, devem ser selecionados 196 elementos amostrais para se obter os níveis de exatidão desejados. Considerando-se que o número total de segmentos gerados para as classes de interesse (Asfalto, Concreto e Terra) foi de 15.572, o número de elementos amostrais Equação 4.10 avaliados foi de 200.

Dessa forma, para cada classe que representa, efetivamente, um tipo de pavimentação de via, foi calculado o número mínimo de elementos amostrais entendidos como adequados para a análise, em função da proporção de segmentos de cada uma, conforme apresentado na Figura 19 e Tabela 6.




Figura 19 – Proporção de segmentos gerados por classe de interesse.

Tabela 6 – Número de elementos amostrais selecionados para a análise.

Classe	No. de segmentos	% do total	No. de segmentos	No. de segmentos aprox.
Terra	1. 302	8,36%	16,72	17
Concreto_b	1. 281	8,23%	16,45	16
Concreto_a	8. 136	52,25%	104,50	105
Asfalto	4. 853	31,16%	62,33	62
Total	15. 572	100	200	200

Para distribuir as amostras sobre a área de estudo, adotando-se um esquema aleatório estratificado, foi empregado o *software Ecognition*, na geração de um arquivo contendo os segmentos que constituíram as classes de interesse: Asfalto, Concreto_a, Concreto_b e Terra, o qual foi exportado para o *software Erdas*, no qual foi feita a seleção aleatória dos polígonos usados como elementos amostrais. Cada um desses polígonos é identificado por um número, o qual é usado na seleção aleatória dos elementos amostrais.

Cada um desses polígonos tem um número identificador consecutivo o qual é utilizado na seleção do mesmo, aleatoriamente.

Na seleção aleatória dos segmentos ou polígonos, foi elaborada uma tabela no Excel com a operação (Aleato-rioentre). Uma tabela contendo a totalidade dos polígonos amostrados aleatoriamente está no Apêndice A.

Com os números aleatórios e os arquivos da classificação e segmentos (Figura 20), procedeu-se à seleção dos segmentos ou polígonos, conforme aos números aleatórios para a elaboração da matriz de confusão ou de erros




Figura 20 – Seleção dos segmentos na imagem e no mapa vetorial.

Foram selecionados (aleatoriamente) polígonos de diferente tamanho. Na Figura 20, estão indicadas as duas imagens na seleção dos polígonos, com o respectivo identificador de cada polígono. O trabalho de identificação dos polígonos foi realizado conspicuamente, para se obter os respectivos valores indicados na tabela.

6 RESULTADOS E ANÁLISES

Nesta seção, reúnem-se o resultado e a análise da classificação, de duas formas: qualitativa e quantitativa. No primeiro caso, procurou-se avaliar visualmente o resultado da classificação, comparando-o com a imagem original, examinando e verificando se a identificação das classes propostas foi coerente com a existência das mesmas, na realidade, através de visita *in loco*. Já a forma quantitativa baseia-se na estimativa estatística, a partir da matriz de confusão e o cálculo de coeficiente *kappa*. Ao final, avalia-se o desempenho do procedimento da classificação, por meio do grau de incerteza, que é apresentado por classes, em forma de mapas.

6.1 Resultados intermediários

6.1.1 Parâmetros da segmentação multiresolução

O parâmetro da segmentação multiresolução que delimitou melhor as variações espectrais observadas nas vias, para cada tipo de pavimento caracterizado na chave de interpretação (Quadro 12), é o seguinte: escala 30, forma 0,1 e compacidade 0,5. O Quadro 12 apresenta os parâmetros usados na segmentação multiresolução da ortoimagem, com um peso constante para todas as bandas espectrais.

Quadro 12– Parâmetros usados para a segmentação- único nível.

	Ajustes de segmentação	
	Pesos das bandas multiespectrais	1.1.1.1.1.1
	Parâmetro da escala	30
	Composição do critério de homogeneidade	
	Forma	0,1
	Compacidade	0,5

6.2 Áreas classificadas

A classificação foi feita na área-teste para sua avaliação e logo projetada à área de estudo. Na Figura 21, observam-se as classificações da área-teste e a área de estudo.




Figura 21 – Classificação área-teste e área de estudo.

A Figura 22 focaliza os resultados da classificação dos tipos de pavimentos das vias, assim como: a imagem das quadras e vias antes da edição; a edição das quadras e malha viária e a classificação.




Figura 22 – Quadras e vias originais (a), quadras e vias editado (b), e vias classificadas (c).

Na Figura 23, apresenta-se o mapa temático, com uma superfície total de 72,26 hectares resultado da classificação. No mapa temático opto-se por uma legenda com cinco classes: Asfalto, Concreto_a, Concreto_b, Terra e Outros; na classe Outros quedarão incluídas as classes anteriormente definidas como: carros, fundo, seta, quadras, etc.




Figura 23 – Área de estudo

A classificação da área de estudo fornece informação importante, no contexto desta pesquisa, porque revela as características de um setor com toda diversidade de tipos de pavimentos, presentes nas vias da cidade.

As Figuras 24 e 25 apresentam os mapas da área de estudo, classificados com os tipos de pavimentos (Asfalto, Concreto_a, Concreto_b e Terra), com um detalhe de duas áreas.




Figura 24 – Mapa da área de estudo classificado com os tipos de pavimentos – detalhe 1^{ra} área.

No mapa da Figura 24 observa-se uma área central da classificação com os tipos de pavimentos Concreto_a e Asfalto, os quais concordam com a realidade do trabalho de campo. Na parte inferior esquerda da ampliação também apreciamos um câmbio de tipo de pavimento de Concreto_a para Asfalto, sendo certo na pratica.





Figura 25 – Mapa da área de estudo classificado com os tipos de pavimentos – detalhe 2^{da} área.

Já, no mapa da Figura 25, detectam-se três tipos de pavimentos Asfalto, Concreto_a e Terra, este último de uma cor magenta, representando os buracos na via urbana os quais foram confirmados no trabalho de campo, ao igual que o cambio de tipo de pavimento de Asfalto para Concreto_a como é observado na parte inferior.


6.3 Análise qualitativa

Observam-se, na Figura 26 (a), os resultados da classificação da imagem de um setor interno (cruzamento) de vias, que são apresentados na maior parte da imagem. Com base em uma análise visual, percebe-se a classificação da via em Concreto_a com a classificação da Terra representando os respectivos buracos. Na Figura 26 (b), verifica-se uma via particular (vias do sistema Transmilenio), a qual foi incluída para ressaltar os tipos de pavimentos da classificação, evidenciando uma boa classificação, ao identificar corretamente o Asfalto (ponte veicular) e o Concreto, os carros foram imersos dentro de cada uma das classes de tipos de pavimentos mediante a condição de *borde do pixel* maior o igual a um.

O resultado geral da classificação tem um comportamento bem coerente, o qual pode ser constatado nos mapas da classificação.



a.








b.

Figura 26 – Imagem com exemplos da classificação (a), (b).

Nas Figuras 26 (a) e (b), nota-se a classificação dos alvos, de acordo com as cores e regras estabelecidas na classificação.

No Quadro 13, visualiza-se o resultado da interpretação, nos três domínios da imagem: composição colorida RGB (1,2,3); fotografia *in loco*, e classificação ou domínio dos objetos.

Quadro 13 – Composição colorida RGB (1,2,3), fotografias *in loco* e classificação.

Classe	Composição da ortoimagem RGB (123)	Fotografia <i>in loco</i>	Classificação	Objetos
Via com pavimento de Concreto_a				Objetos de forma retangular, simétricos e compactos.
Via com pavimento de Concreto_b				Objetos de forma retangular, simétricos e com orientação.
Via com pavimento de Asfalto				Objetos de forma retangular, simétricos e compactos.
Via de Terra				Objetos assimétricos, Forma irregular.
Outros				Objetos de formas retangulares e circulares, assimétricos.

6.4 Análise quantitativa

A matriz de erros, para a imagem classificada, possibilita a comparação do resultado da classificação com dados de referência representados pelos segmentos coletados para cada classe, por meio de um esquema de amostragem aleatório, porém estratificado por categoria, conforme a Tabela 7.

Tabela 7 – Matriz de confusão da classificação das classes de interesse.

		VERDADE TERRESTRE					Σ
		Asfalto	Concreto_a	Concreto_b	Terra	Outros	
CLASSIFICAÇÃO	Asfalto	42	3	0	0	17	62
	Concreto_a	1	75	1	1	27	105
	Concreto_b	0	0	10	0	6	16
	Terra	0	0	2	13	2	17
	Outros	0	0	0	0	0	0
Σ		43	78	13	14	52	200

A matriz de confusão mostra que, do total de 200 segmentos ou polígonos analisados, 60 polígonos foram classificados erroneamente. Como consequência, a exatidão global (eg) computada foi de 70%. Baseando-se apenas nesse resultado, pode-se concluir pela probabilidade de 70% das categorias classificadas na ortoimagem terem sido também verificadas em campo. No entanto, Congalton e Green (1999) alertam que, com base apenas no índice de exatidão global, as inferências feitas podem gerar equívocos, de modo que o cálculo e a análise dos índices de exatidão do usuário (eu) e do produtor (ep) conferem maior significado aos dados, evidenciando o percentual de confusão entre as categorias.

No experimento realizado, o coeficiente de concordância *Kappa* (*k*) calculado foi de 58,19%, sendo esse resultado considerado “bom”, de acordo com a Tabela 3 de referência de Landis e Koch (1977) para desempenho da classificação. A exatidão global tende a superestimar o resultado da classificação, pois considera apenas o percentual de elementos amostrais corretamente classificados, enquanto o coeficiente

de concordância *Kappa* tem maior consistência, por levar em conta o percentual de plena concordância e a proporção de concordância por causalidade.

Para Lillesand, Kieffer e Chipman (2004), o coeficiente *kappa* serve como um indicador do grau em que a percentagem dos valores corretos da matriz de confusão se deve à “verdade” versus a “probabilidade” de concordância. Nesse caso, o coeficiente *kappa* obtido, de 58,19%, deve ser entendido como uma indicação de que a classificação obtida foi 58,19%, melhor do que seria um resultado originado através de uma assinatura aleatória dos polígonos.

Para a análise da acurácia por classe, foram computadas a exatidão do usuário (eu) e a exatidão do produtor (ep). O primeiro índice é se obtém pelo resultado da classificação, ao passo que o segundo, considera a imagem de referência. Os valores complementares a esses se referem, respectivamente, aos erros de comissão (e_c) e de omissão (e_o) das classes mapeadas. Além disso, também foi calculada a concordância *kappa* por classe. Os valores dessas estatísticas estão listados na Tabela 8.

Tabela 8 – Índices de exatidão por classe.

Classes	eu (%)	e_c (%)	ep (%)	e_o (%)	κ (%)
Asfalto	67,74	32,26	97,67	2,33	96,71
Concreto_a	71,42	28,58	96,15	3,85	92,37
Concreto_b	62,50	37,50	76,92	23,08	75,03
Terra	76,47	23,53	92,85	7,15	92,23

Conforme pode ser observado na Tabela 8, as classes *Concreto_a* e *Terra* foram aquelas que apresentaram maior exatidão do usuário. Trata-se de dois alvos facilmente discrimináveis, nas bandas espectrais que foram utilizadas na classificação. A classe com menor índice de exatidão do usuário foi *Concreto_b*, com padrões de resposta espectral similares às de *Terra* e *Concreto_a*, nos locais pavimentados mais recentemente.

Em acréscimo, os maiores índices de exatidão do produtor foram provenientes das classes *Asfalto* e *Concreto_a*, representando as maiores proporções de cobertura da área de estudo. Por outro lado, a classe *Concreto_b* forneceu o menor índice de exatidão do produtor, representando a menor proporção de cobertura da área

de estudo. Os erros de omissão (e_o) foram menores que os de comissão (e_c). Embora os resultados sejam similares, Rosenfield e Fitzpatrick-Lins (1986) apud Prado (2009) recomendam considerar o valor de *kappa* em relação aos demais coeficientes de concordância computados por classe.

A concordância *kappa* por classe é considerada entre muito boa e excelente, ficando entre 75 e 97%. Na Figura 27, verifica-se a distribuição dos resultados do índice *kappa* por classe.




Figura 27 – Coeficiente *kappa* para cada classe.

Pode-se dizer que não existem grandes discrepâncias nas classes analisadas, porque, de acordo com Landis e Koch (1977), nenhum dos resultados da classificação ficou abaixo de 60%.

Para mostrar o melhor desempenho da classificação quando se utiliza também as imagens dos componentes principais como entrada para a classificação, foi realizada a classificação apenas das bandas espectrais. A matriz de confusão resultante da análise da acurácia dessa classificação é mostrada na Tabela 9.

Tabela 9 – Matriz de confusão da classificação das classes de interesse sem componentes principais.

		VERDADE TERRESTRE					Σ
		Asfalto	Concreto_a	Concreto_b	Terra	Outros	
CLASSIFICAÇÃO	Asfalto	27	26	4	2	3	62
	Concreto_a	22	68	5	3	7	105
	Concreto_b	2	8	6	0	0	16
	Terra	5	7	4	0	1	17
	Outros	0	0	0	0	0	0
	Σ	56	109	19	5	11	200

O coeficiente de concordância *Kappa* (**k**) calculado a partir da matriz mostrada na Tabela 9 foi 19,77%, sendo esse resultado considerado “ruim”, de acordo com a Tabela 3 de referência de Landis e Koch (1977), confirmando o melhor desempenho da classificação quando se acrescenta componentes principais como dados de entrada.

Além da classificação por regras usando apenas as três bandas espectrais (sem as componentes principais) foi realizado um teste aplicando-se o classificador convencional da distância mínima da média (Nearest Neighbor) às três bandas espectrais juntamente com as imagens derivadas da transformação em componentes principais. Assim, para as mesmas classes anteriores, foi utilizada a abordagem de padrão (standard) do vizinho mais próximo.

Na Figura 28 apresentam-se os resultados da classificação dos tipos de pavimentos utilizando o método do vizinho mais próximo, já aplicado o parâmetro de contexto que possibilitou a delimitação das quadras.




Figura 28 – Utilização do descritor espacial das quadras (a), classificação pela distância mínima da média (b).

Para avaliar o desempenho da classificação pelo vizinho mais próximo, foi estimada a matriz de confusão, com o mesmo conjunto amostral usado nos procedimentos anteriores, a qual é mostrada na Tabela 10.

Tabela 10 – Matriz de confusão da classificação das classes de interesse pelo método do vizinho mais próximo.

		VERDADE TERRESTRE					Σ
		Asfalto	Concreto_a	Concreto_b	Terra	Outros	
CLASSIFICAÇÃO	Asfalto	46	0	6	0	10	62
	Concreto_a	75	8	2	0	20	105
	Concreto_b	13	0	1	0	2	16
	Terra	11	1	5	0	0	17
	Outros	0	0	0	0	0	0
	Σ	145	9	14	0	32	200

O coeficiente de concordância Kappa (k) calculado a partir da matriz mostrada na Tabela 10 foi 19,50%, sendo esse resultado considerado “ruim”, de acordo com a Tabela 3 de referência de Landis e Koch (1977), confirmando o melhor desempenho da classificação proposta nessa pesquisa, ou seja, usando uma abordagem *Fuzzy*.

A utilização de regras *fuzzy* permite a estimativa da estabilidade da classificação e, conforme proposto, essa avaliação foi adotada para a classificação resultante da aplicação de regras *fuzzy* ao conjunto de bandas espectrais e componentes principais. A imagem de incerteza está representada pelos indicativos das áreas de estabilidade da classificação dos tipos de pavimentos das vias urbanas, conforme evidenciado na Figura 29. Nela, observa-se um predomínio dos objetos estáveis de cor verde, isto é, os objetos com pouca estabilidade ou menor que 0,14 são apresentados em vermelho, com degradação para o verde, à medida que ficam com maior estabilidade.




Figura 29 – Estabilidade da classificação dos tipos de pavimentos das vias.

Para análise, da estabilidade, foi, necessário um detalhamento dos segmentos ou polígonos que exibem uma estabilidade maior, ou uma estabilidade muito baixa (detalhe da Figura 29). Os indicadores estatísticos da estabilidade da imagem são focalizados na Tabela 11.

Tabela 11 – Indicadores estatísticos de Estabilidade.

Classes	Objetos	Media	Desvio padrão	Mínimo	Maximo.
Asfalto	4.853	0,668	0,280	0,1003	0,9886
Concreto_a	8.136	0,749	0,260	0,1004	0,9998
Concreto_b	1.281	0,373	0,196	0,1002	0,8938
Terra	1.302	0,591	0,260	0,1012	0,9805

A Tabela 11 mostra o intervalo da variação da função fuzzy para cada classe, com uma média e desvio-padrão por classe.

Na Figura 30 (a), nota-se a seleção de uma via e um dos polígonos da mesma classificada com o tipo de pavimentos Asfalto, enquanto, na Figura 30 (b), observa-se o mesmo setor e polígono selecionado, porém adotado da imagem de estabilidade com um valor de 0.13 em cor vermelha, junto ao qual temos outro polígono, também classificado como asfalto, mas com uma maior estabilidade 0,76 em cor verde (Figura 30 (c)). Dessa forma, observa-se a estabilidade e a representação da mesma, dentro da imagem. Os valores de estabilidade para cada uma das classes variam de acordo com a estatística de estabilidade dos objetos. No Apêndice B mostra-se um mapa com duas áreas uma ao extremo da outra, mostrando a estabilidade gradual do Asfalto e do Concreto_a.



Em cor vermelho, e polígono vermelho, representa-se a estabilidade baixa do polígono de Asfalto com um valor de 0,13.



C.

Figura 30 – Imagem classificada (a), polígono da imagem de baixa estabilidade (b), polígono com maior estabilidade (c).

Na Figura 30, o polígono demarcado em vermelho, porém com coloração verde escura, mostra alta estabilidade, com valor 0,76. Nesse caso, o pavimento foi classificado como Asfalto, no entanto a estabilidade dos vários segmentos que compõe a via podem variar em relação a essa classe.

7 CONCLUSÕES

O objetivo principal deste trabalho foi classificar os tipos de pavimentos das vias urbanas de um setor da cidade de Bogotá, D.C, a partir de uma ortoimagem de alta resolução espacial, usando a abordagem de análise orientada a objeto, classificação aceita ao se obter uma análise estatística dos resultados como boa, com um coeficiente de concordância *Kappa (k)* de 58,19%, Tabela 3 de referência de Landis e Koch (1977).

Para o desenvolvimento da classificação dos tipos de pavimentos das vias urbanas, é necessário conhecer as características espectrais, espaciais e contextuais das feições de interesse, presentes na área de estudo. A heterogeneidade das feições das vias, em termos de forma, distribuição e tipos de pavimentos usados, fizeram que a segmentação ficasse mais homogênea apresentando um ponto ótimo com os parâmetros de escala, forma e compacidade selecionados. A separação das Quadras foi, mais eficiente a partir dos atributos espaciais que dos espectrais, quanto à forma e à área, que com respeito aos outros tipos de alvos na imagem.

Na classificação, o fornecimento de dados adicionais, como Componentes Principais, foi importante durante todo o processo, desde a segmentação até a produção do mapa temático. Nesse caso, a utilização do mapa vetorial, na abordagem da segmentação, foi fundamental para o fornecimento dos objetos Quadras, oferecendo, além da separação das vias urbanas, um rendimento em tempo nos processos da classificação.

Os resultados obtidos nesta pesquisa foram avaliados qualitativamente e quantitativamente, permitindo estimar um grau de confiabilidade para conhecer com boa exatidão os tipos de pavimentos presentes nas diferentes vias da área de estudo. E são motivadores da continuidade de estudos nessa linha, analogamente a o domínio das técnicas e ao conhecimento que se tenha dos novos métodos de classificação, cujo pressuposto teórico está abordando e ultrapassando os estudos dos alvos urbanos e intraurbanos, com imagens de sensores remotos aerotransportadas de resolução espacial ou GSD maiores que 0.15 m.

Quanto à utilização dos dados gerados, nesta pesquisa, que 31,16% dos polígonos corresponderam ao tipo de pavimentos em *Asfalto*, 60,48% ao tipo de pavimentos em *Concreto* e 8.36% em *Terra*, pode-se afirmar que o mapeamento pode

subsidiar a criação de uma série de outras informações, para o benefício do planejamento e gestão urbana da cidade.

O resultado da classificação não pretende apresentar o estado de conservação ruim ou bom das vias urbanas, mas prover meios de suprir a demanda por informações precisas e rápidas sobre a existência de vias que apresentam condições não aptas para a mobilização dos veículos e das comunidades em geral.

O processo de classificação baseada em objeto, tem-se mostrado muito dependente do conhecimento do operador, ainda que se possam observar avanços promissores, seja para caracterização dos objetos através da segmentação das imagens, seja para modelar as regras empregadas na discriminação dos mesmos, razão pela qual o acompanhamento da classificação com os estudos feitos *in situ* foi importante na validação da classificação e nos testes da mesma.

Com base nos resultados obtidos, pode-se concluir que o mapa de classificação dos tipos de pavimentos das vias urbanas, elaborado a partir da classificação semi-automática da ortoimagem, apresentou índices de exatidão considerados como bons.

Como consideração final, constata-se que os objetivos propostos nesta pesquisa foram alcançados, no que se refere à classificação dos tipos de pavimentos das vias urbanas, a partir de imagem de alta resolução espacial, usando a abordagem de classificação orientada a objeto e a análise da qualidade da classificação obtida em uma área da cidade de Bogotá, Colômbia.

8 RECOMENDAÇÕES

Estudos mais aprofundados devem ser realizados, a fim de se verificar se a classificação é adequada para a análise dos pavimentos das vias da cidade como um todo. Além disso, é necessário fazer-se um aprofundamento nas áreas ou zonas de transição entre os tipos de pavimentos, como *Asfalto-Terra*, e *Concreto-Terra*.

O sensor remoto (a câmara digital Ultracam-D) trabalha com a banda ou canal infravermelho, o qual não foi fornecido para esta pesquisa, de sorte que se recomenda usar-la, devido a seu prático emprego na separação de outras classes como, por exemplo, vegetação.

A utilização dos mapas vetoriais, modelos digitais de superfície, componentes principais, textura, da área de estudo, são recursos necessários que devem ser aproveitados, porque proporcionam um rendimento em tempo e fornecem uma melhor definição, na segmentação dos objetos.

Os critérios de escala, forma e compacidade são critérios de cada estudo que não podemos generalizar, pelo fato de haver trabalhos similares com imagens de alta resolução espacial, portanto, o conhecimento do intérprete é fundamental na criação de suas próprias regras.

O englobamento dos tipos de pavimentos das vias urbanas em três classes foi muito geral, devendo-se considerar as áreas de transição ou intermediárias, bem como outros possíveis materiais, para um melhor critério na classificação.

Por fim, é oportuno enfatizar que uma prévia capacitação no manejo do *software* é fundamental para o rendimento e efeitos benéficos da investigação.

REFERÊNCIAS BIBLIOGRÁFICAS

ANTUNES, A.F.B. **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial**. 2003 147 f. Tese (Doutorado em Ciências Geodésicas) – Universidade Federal do Paraná, Curitiba.

ANTUNES, A.F.B., LINGNAU, C. e CENTENO DA SILVA, J. (2003): “**Object oriented analysis and semantic network for high resolution image classification**”, Anais XI SBSR, Belo Horizonte, Brasil, 5-10 abril 2003, INPE, pp. 273-279.

ARAÚJO, E. ; KUX, H. **Análise multi-temporal de cenas do satélite QuickBird usando um novo paradigma de classificação de imagens e inferências espaciais: estudo de caso Belo Horizonte (MG)**, 2006, 159 p. Dissertação (Mestrado em Sensoriamento Remoto), INPE, São José dos Campos, 2006.

AZEVEDO et al., **Redes Neurais com aplicações em controle e em Sistemas Especialistas**. Visual Books. Florianópolis. 2000.

BAATZ, M.; SCHÄPE, A. (2000): “**Multi-resolution segmentation: an optimization approach for high quality multi-scale image segmentation**”. En J. Strobl, T. laschke y G. Griesebner (Eds.), *Angewandte Geographische Informationsverarbeitung XII*, Wichmann, Heidelberg, pp. 12-23.

BAATZ, M. S (2001). **Methods and Concepts**. Munchen. Disponível em: www.definiens.com. Acesso em: 03 setembro. 2010.

BARNSLEY, M. J.; BARR, S. L. Inferring urban land use from satellite sensor images using kernel-based spatial reclassification. **Photogrammetric Engineering and Remote Sensing**, v. 62, p. 949-958, 1996.

BENZ, U.; HOFMANN, P.; WILLHAUCK, G.; LINGENFELDER, I; HEYNEN, M. **Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information**. ISPRS Journal of Photogrammetry & Remote Sensing, v. 58, n. 3-4, p. 239-258, Jan. 2004.

BISHR, Y. **Semantic aspects of interoperable GISG**. ITC publication No. 56, Enschede. 1997.

BLASCHKE, T. **Object-based contextual image classification built on image segmentation**. In: *advances in techniques for analysis of remotely sensed data*, 2003. Proceedings... IEEE, p. 113-119.

BLASCHKE, T.; HAY, G. **Object-oriented image analysis and scale-space: theory and methods for modeling and evaluating multiscale landscape structure**. 2002 <http://www.definiens.com/search.php?search=Objectoriented+image+analysis+and+le>. Acesso em 11 setembro 2010.

BLASCHKE, T.; LANG, S.; HAY, G.J. **Object Based Image Analysis, Spatial Concepts for Knowledge Driven Remote Sensing Applications**. Springer –Verlag Berlin Heidelberg. 2008.

BLASCHKE, T.; LANG, S.; LORUP, E.; STROBL, J.; ZEIL, P. Object-oriented processing in and integrated GIS/remote sensing environment and perspectives for environmental applications. In: Cremers, A.; Greve, K. org. **Environmental information for planning, politics and the public, Metropolis**. Marburg. V. 2, 2000. 555-570 p.

BLASCHKE, T.; KUX, H. J. H. **Sensoriamento Remoto e SIG avançados - novos sistemas sensores: métodos inovadores**. São Paulo: Oficina de Textos, 2007, 2ª ed., 303 p.

CAETANO, M.; MATA, F.; FREIRE, S. Accuracy assessment of the portuguese CORINE land cover map. In: MARÇAL, A. **Global developments in environmental earth observation from space**. Rotterdam: Millpress, 2006. Disponível em: < http://www.igeo.pt/pesquisa_produtos.asp >. Acesso em: 06 setembro. 2010.

CÂMARA, G.; MEDEIROS, J.S. **Princípios básicos em geoprocessamento**. In: Assad, E.D.; Sano, E. E. Ed. **Sistemas de Informações Geográficas. Aplicações na Agricultura**. Brasília: Embrapa –SPI / Embrapa-CPAC, 1998. Cap 1, p.3-11.

CAMPOS, V. O. **Um método de modelagem do conhecimento multitemporal para a interpretação automática de imagens de Sensores Remotos**. 2005. 172 f. Tese (mestrado Pontifícia Universidade Católica de Rio de Janeiro), PUC.Departamento de Engenharia Elétrica.

CONGALTON, R. G.; GREEN, R. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. Boca Raton: Lewis Publishers, 1999, 137 p.

COSTA, G.A.; PINHO, C.M.D.; FEITOSA, R.Q.; ALMEIDA, C.M.; KUX, H.J.H.; FONSECA, L. M. G.; OLIVEIRA, D. INTERIMAGE: An Open Source Platform for Automatic Image Interpretation In: **Simpósio Brasileiro de Geomatica e V Colóquio Brasileiro de Ciências Geodésicas**. Presidente Prudente, UNESP, 2007.

CLÉMENT, V. et al., **Interpretation of remotely sensed images in a context of multisensor fusion using a multispectral architecture**. IEEE Transactions on Geoscience and Remote Sensing. Vol. 31, No. 4, p. 779-791. 1993



CHUVIECO, E. **Teledetección ambiental**: la observación de la Tierra desde el espacio. 1. ed. Barcelona: Ariel Ciència, 2002. 586 p.

DARWISH A, LEUKERT K, REINHARDT W (2003), **Image Segmentation for the Purpose of Object-Based Classification. Geoscience and Remote Sensing Symposium. IGARSS 2003. Proceedings 2003 IEE International 3 pp.** 2039-2041.

DEFINIENS Ecognition: 2009, **Guide Deloper 8 Reference Book Document v.1.2.0** Disponível em: <<http://www.definiensimaging.com/down/ecognition>>. Acessado em 01 de Junho de 2010.

DEFINIENS. Ecognition: **User Guide 4. Germany**, 2003, 480 p. Disponível em: <<http://www.definiens-imaging.com/down/ecognition>>. Acesso em: 05 abr. 2010.

EASTMAN, J R. Idrisi andes: **guide to GIS and image processing**. Manual version 15. Worcester: Clark University, 2006.

FAN, G.; XIA, X. 2001. **A joint multicontext and multiscale approach to Bayesian image segmentation**. IEEE Transaction on Geoscience and Remote Sensing. Vol 39, N° 2, p. 2680-2688.

FEITOSA, R.Q.; MATTOS, C.; SANTOS, R.V.1; RENGÓ, L. F. G.; PEREIRA; A. A. C. Impacto de técnicas baseadas em conhecimento na análise de imagens de média resolução para mapeamento de desflorestamento na Amazônia. In: Simpósio Brasileiro de Sensoriamento Remoto, as., 2005, Goiânia. **Anais**. São José dos Campos: INPE, 2005. P. 4065 – 4072. 1 CD-ROM.

FRANK, A.; RAUBAL, M. Formal specification of image schemata – a step towards interoperability in geographic information systems. Spatial Cognition and Computation 1: p 67-101. The Netherlands. 1999.

GEOBIA, 2008: University of Calgary, page <<http://wiki.ucalgary.ca/page/GEOBIA>>. Acessado em 11 de Junho de 2010.

GONZÁLEZ, R.C.; WOODS, R.E. **Processamento de Imagens Digitais**. Edgard Blücher Ltda. São Paulo, 2000, 509 p.

GOODCHILD, M. F.; SHI, W.; FISHER, P. F. Spatial data quality. London: Taylor & Francis, 2002.

GORTE, B. **Probabilist segmentation of remote sensing data**. ITC, Journal, N° 63, The Netherlands. 1998.

GUNST, M.; VOSSELMAN, G. A semantic road model for aerial image Interpretation. In *Semantic Modeling for Acquisition of Topographic Information from Images and Maps*, Edited by Förstner Lutz Plümer. Verlag. Belin. 1997.

HARALICK, R. ; SHAPIRO, L. **Image segmentation techniques**. **Computer Vision, Graphics, and Image Processing**. v. 29, p. 100-132, 1985.

HOFMANN, P; REINHARDT, S. Detecting buildings and roads from IKONOS data using additional elevation information. **GeoBIT/GIS**, n 6 p. 28-33, June 2000.

INPE – Instituto Nacional de Pesquisas Espaciais. SPRING. 5.1.6, sistema de ajuda on-line do spring- São José dos Campos, 2010. Disponível em:< <http://www.dpi.inpe.br/spring/portugues/manuais.html> >, Acesso em 16 setembro 2010.

INPE – Instituto Nacional de Pesquisas Espaciais. Sistema de ajuda on-line do spring-Manuais. Tutorial de Geoprocessamento. São José dos Campos, 2011. Disponível em:< <http://www.dpi.inpe.br/spring/portugues/manuais.html> >, Acesso em 16 fevereiro 2011.

IVITS, E.; KOCH, B. 2002. Object-Oriented Remote Sensing Tools for Biodiversity Assessment: European Approach. University of Freiburg, D.E. Disponível em < http://www.definiens.com/scientific_papers.php?cat_id=1&dt=2002&link_id=24&sublink_id=25>. Acesso em 12 de setembro 2010.

JENSEN, J. R. **Introductory digital image processing: a remote sensing perspective**. 2. ed. New Jersey: Prentice Hall, 1996.

KANT, E. **Critica da Razão Pura**. Ed. Acrópolis / Ebooks Brasil. Disponível em < http://virtualbooks.terra.com.br/freebook/didaticos/Critica_da_Razao_Pura.htm >. Acesso em 12 de setembro 2010.

KIM; M.; XU, B.; MADDEN, M. **Object-based vegetation type mapping from on orthorectified multispectral IKONOS image using ancillary information**. In: INTERNATIONAL CONFERENCE ON OBJECT-BASED IMAGE ANALYSIS, 2, 2008, Calgary Alberta, Canada. **Proceedings...** Calgary Alberta: ISPRS, 2008. p. 1-5.

LABA, M. et al., Conventional and fuzzy accuracy assessment of New York gap analysis project land cover map. **Remote Sensing of Environment**. v.81, n. 2-3, p.443-455. Aug. 2002.

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

LANG, S. **Multi-resolution representation of landscape structures utilizing object-based image interpretation**. In: AGGER,P.; BITSCH, R. Studying multifunctional Landscapes. *Landscapes Ecological Papers*, N. 16, pp. 7-14, 2001.



LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote sensing and image interpretation**. New York: John Wiley and Sons, 2004. 763 p.

MEINEL, G.; NEUBERT, M. A Comparision of segmentation programs for high resolution remote sensing data. *Int. Arch. of Photogrammetry, Remote Sensing and Spatial Information Sciences*. p. 1097-1102, 2005.

MELO, D. H. C. T. B. **Uso de dados Ikonos II na análise urbana: testes operacionais na zona leste de São Paulo**. Tese Mestrado, São José dos Campos: INPE, 2003.146p.

MESEV, V. *Remotely Sensed Cities*, London, UK, Taylor & Francis, 2003.

MITRI, G. H.; GITAS, I. Z. A performance evaluation of a burned área object-based classification model when applied to topograhically and non-topographically correct TM imagery. *International Journal of Remote Sensing*. Vol. 25, No. 14, July 2004, PP.2863-2870

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

MOLENAAR, M.; CHENG, T. Fuzzy saptial objects and their dynamics. *ISPRS Journal of Photogrammetry & Remote Sensig*, No. 55, P. 164- 175. 2000.

MONICO, J. F. G.; DAL PÓZ, A. P.; GALO, M.; DOS SANTOS, M. C.; DE OLIVEIRA, L. C. **Acurácia e precisão: Revendo os conceitos de forma acurada**. *Bol. Ciênc. Geod. , se. Comunicações*, Curitiba, v. 15, nº 3, p.469-483, jul-set, 2009.

NAVULUR, K. **Multispectral image analysis using the object-oriented paradigm**. CRC press. Taylos & Francis Group. Boca Raton, FL. 2007.

NÓBREGA, R. A. **Detecção da malha viária na periferia urbana de São Paulo utilizando imagens orbitais de alta resolução espacial e classificação orientada a objetos** / R.A. de A. Nóbrega – Ed. rev. São Paulo, 2007, Tese (Doutorado) – Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Transportes.

PINHO, C. M. D. **Análise orientada a objetos de imagens de satélite de alta resolução espacial aplicada à classificação de cobertura do solo no espaço intraurbano: o caso de São José dos Campos - SP**, São José dos Campos, 2005, 181 p. 2005 (INPE-14183-TDI/1095) Dissertação (Mestrado em Sensoriamento Remoto), INPE, 2005.

PINHO, C.M.D ; FEITOSA, F.F; KUX, H.: **Classificação automática de cobertura do solo urbano em imagem Ikonos: Comparação entre a abordagem pixel a pixel e orientada a objetos.** In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR) 12, 2005. São Jose dos Campos: INPE, Artigos p 4217- 4224.

PRADO, F. A. **Sistema hierárquico de classificação para mapeamento da cobertura da terra nas escalas regional e urbana.** 2009. 164 f. Tese (mestrado) Universidade Estadual Paulista, Campus de Presidente Prudente.

RENNÓ, C.D.; SANTÁNA, S. J.; FREITAS, C. C.; FITZPATRICK, K. Avaliação das incertezas nas classificações de máxima verossimilhança e contextual de modas condicionais iterativas. In: GISBRASIL '99, 1999, Salvador. **Anais...**1999.

RESENDE, M.R. Investigação do uso de imagens de sensor de sensoriamento remoto hiperespectral e com alta resolução espacial no monitoramento da condição de uso de pavimentos rodoviários – Dissertação (Mestrado) – escola Politécnica da Universidade de São Paulo. Departamento de Transportes. São Paulo, 2010

RICHARDS, J ; JIA, X. **Remote Sensing Image Analysis, and Introduction.** Spring – Verlag. Berlim. 1999.

ROSENFELD, G. H.; FITZPATRICK-LINS, K.; A Coefficient of Agreement as a Measure of Thematic Classification Accuracy. -**Photogrammetric Engineering and Remote Sensing**, v. 52, n. 2, p. 223 – 227. 1986.

RUMBAUGH, J.; BLAHA, M; HEDI F T.C.: BARRT S.L. **Técnica de modelado de objetos.** OMT. ed. Prentice Hall, 1996.

SANDE, C. J.; JONG, S. M.; ROO, A. P.; JHON, P. A. Segmentation and classification approach of IKONOS-2 imagery for land cover mapping to assist flood risk and flood damage assessment. **International Journal of Applied Earth Observation and Geoinformation** v.4 n.2, p.217-229, 2003.

SHACKELFORD, A. K.; DAVIS, C. H., 2003, A combined fuzzy pixel-based and object-based approach for classification of high-resolution multispectral data over urban areas, **IEEE Transactions on Geoscience and Remote Sensing**, 41, pp. 2354-2363.

SOLBERG, Anne et al., **A Markovv Random Field model for classification of multisource Satellite Imagery.** IEEE Transations on Geosciences and Remote Sensing. Vol 34, january. 1996.

STEELE, B.M.; WINNE, J. C.; REDMOND, R. L. Estimation and mapping or misclassification probabilities for thematic land cover maps. **Remote Sensing of Enviroment**, v. 66, n. 2, p. 192-202, 1998.

TON, Jezching et al., **Knowledge-based segmentation of Landsat images**. IEEE. Transactions on Geosciences and Remote Sensing. Vol 29. Nº1, março. 1991.

VIEIRA, V.P.P.B. et al.,; **Sistemas Inteligentes - Aplicações a Recursos Hídricos e Ciências Ambientais**; Editora Universidade - ABRH; 1999.

YOURDON, E. Object – **Oritented Systems Design**: an itegrated approach. New Jersey **Prentice-Hall**. 1994.

YU, Q. et al., Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. **Photogrammetric Engineering and Remote Sensing**, v. 72, n. 7, p. 799-811, 2006.

ZADEH, L. A. Fuzzy Sets, In: **Journal Information and Control**, v. 8, p. 339-353, 1965.

ZADEH, L. A. Fuzzy Sets as a basis for a theory of possibility. **Fuzzy Sets and Systems**, 1, 3-28. 1978.

APÊNDICE A

TABELA DE NÚMEROS ALEATÓRIOS PARA CADA CLASSE

Tabela

Números Aleatórios sorteados para cada classe de interesse.

Número	Terra	Concreto_b	Concreto_a	Asfalto
1	2830	3134	2884	11986
2	8405	8355	4128	11071
3	12626	637	11173	903
4	375	2894	9784	4313
5	10359	7761	12907	11095
6	4580	290	624	10775
7	8344	5752	11845	4039
8	14021	4700	9715	11420
9	9505	12445	4973	6590
10	6768	5927	12520	6821
11	9516	5041	3512	10625
12	10009	10696	89	14567
13	9074	9650	6819	2818
14	2109	5890	10326	5386
15	8112	8773	11876	13812
16	11588	133	3375	4683
17	3067		13934	11429
18			8146	14540
19			14174	13898
20			779	5956
21			8930	11559
22			9298	13968
23			87	7488
24			6108	388
25			8235	12381
26			6990	15248
27			13808	4174
28			3098	10001
29			1364	13234
30			13705	13534
31			6598	8196
32			7730	13279
33			6486	14838
34			10790	14362
35			9411	1945
36			5517	10065
37			15236	11130
38			13347	11722
39			6366	8174
40			97	8260
41			5544	4751
42			11643	5547



Classificação dos tipos de pavimentos das vias urbanas a partir de imagem de alta resolução espacial por meio de análise orientada a objeto.

Consecutivo	Terra	Concreto_b	Concreto_a	Asfalto
43			3360	11178
44			5661	14994
45			14257	13001
46			8415	2296
47			6949	1848
48			14634	12140
49			1096	5899
50			82	14859
51			13624	7610
52			15172	1932
53			2136	6823
54			8114	13635
55			10994	14180
56			3264	14151
57			2015	13560
58			474	13337
59			627	2189
60			6501	13985
61			6363	5918
62			4442	578
63			9150	
64			10611	
65			3049	
66			6815	
67			3707	
68			11063	
69			906	
70			5988	
71			3385	
72			483	
73			9663	
74			7573	
75			5248	
76			3298	
77			10397	
78			321	
79			12629	
80			3195	
81			2253	
82			11452	
83			3342	
84			13426	
85			5963	
86			5487	
87			14388	
88			681	
89			4348	



Classificação dos tipos de pavimentos das vias urbanas a partir de imagem de alta resolução espacial por meio de análise orientada a objeto.

Consecutivo	Terra	Concreto_b	Concreto_a	Asfalto
90			4486	
91			14725	
92			12929	
93			10486	
94			9706	
95			2540	
96			11509	
97			1739	
98			8970	
99			1418	
100			4623	
101			8200	
102			331	
103			3012	
104			189	
105			13929	



APÊNDICE B

MAPA DE
ESTABILIDADE DA CLASSIFICAÇÃO

