



**UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE GEOCIÊNCIAS**

**ANÁLISE DA QUALIDADE DE CLASSIFICADORES PARA
IDENTIFICAÇÃO DE ALVOS URBANOS EM IMAGENS
DE ALTA RESOLUÇÃO ESPACIAL - UMA APLICAÇÃO
COM AS IMAGENS DO SATÉLITE WORLDVIEW II**

DISSERTAÇÃO DE MESTRADO n° 45

DENILSON PEREIRA PASSO

Brasília-DF

Março 2013



**UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE GEOCIÊNCIAS**

**ANÁLISE DA QUALIDADE DE CLASSIFICADORES PARA
IDENTIFICAÇÃO DE ALVOS URBANOS EM IMAGENS
DE ALTA RESOLUÇÃO ESPACIAL - UMA APLICAÇÃO
COM AS IMAGENS DO SATÉLITE WORLDVIEW II**

Denilson Pereira Passo

Orientador: Prof. Dr. Edilson Souza Bias

Dissertação de Mestrado apresentada à Banca Examinadora do Instituto de Geociências Aplicadas (Geoprocessamento e Análise Ambiental) da Universidade de Brasília, como exigência para obtenção do título de mestre em Geociências.

Brasília-DF

Março 2013

UNIVERSIDADE DE BRASÍLIA

Instituto de Geociências

**ANÁLISE DA QUALIDADE DE CLASSIFICADORES PARA
IDENTIFICAÇÃO DE ALVOS URBANOS EM IMAGENS
DE ALTA RESOLUÇÃO ESPACIAL - UMA APLICAÇÃO
COM AS IMAGENS DO SATÉLITE WORLDVIEW II**

Denilson Pereira Passo

BANCA EXAMINADORA

Prof. Dr. Edilson Souza Bias

Presidente

Prof. Dr. Edson Eyji Sano

Membro Interno

Prof. Dr. Gilson Alexandre Ostwald Pedro da Costa

Membro Externo

Brasília 28 de março de 2013.

*Aos meus pais,
que além de estarem sempre presentes nas
dificuldades, foram fontes de apoio e
impulso na busca contínua pelo
conhecimento.*

AGRADECIMENTOS

A Deus pela oportunidade e privilégio que me foi dado de compartilhar tamanha experiência e, ao frequentar este curso, perceber e atentar para a relevância de temas que não faziam parte da minha vida; a minha namorada Lucimeire, que por dois anos me aguentou falar todos os dias sobre imagens de satélite, matriz de confusão, mistura espectral, etc.; aos colegas de curso pela espontaneidade e alegria na troca de informações e materiais numa rara demonstração de amizade e solidariedade; ao professor Edilson Souza Bias que, com muita paciência e atenção, dedicou do seu valioso tempo para me orientar em cada passo deste trabalho; e a todos que de alguma maneira estiveram presentes ao longo desses dois anos e contribuíram para a construção deste trabalho.

RESUMO

O desenvolvimento tecnológico em sensoriamento remoto vem proporcionando um grande incremento na qualidade das imagens orbitais, permitindo uma melhor visão dos ambientes intra-urbanos. Um exemplo notável é o satélite WorldView II. Lançado em 2009, suas imagens começaram a ser distribuídas comercialmente em 2010. O satélite possui uma resolução de 50cm na banda pancromática e 2m nas outras 8 bandas espectrais. Apesar deste extraordinário avanço em termos de resolução espacial e espectral, os sistemas tradicionais de processamento de imagens disponibilizam métodos de classificação que sofrem muita influência da mistura espectral devido à multiplicidade de feições observadas nas imagens de alta resolução. Grande parte dessas dificuldades está relacionada às limitações dos classificadores que somente levam em consideração a informação espectral, pois estes não conseguem tratar de forma satisfatória a variabilidade dos diferentes alvos urbanos. Na busca por uma solução, surgiram recentemente pacotes de software que possibilitam a classificação de imagens com base em objetos e que facilitam a representação e processamento de conhecimento humano sobre as características específicas dos alvos de interesse. No entanto, a maioria dos pacotes de software com estas características são proprietários e de difícil acesso devido ao alto custo de suas licenças. Uma alternativa surgiu com a iniciativa de desenvolvimento open source do software InterIMAGE. No presente trabalho, o objetivo foi avaliar as potencialidades e acurácia das classificações geradas pelas metodologias por pixel *Maximum Likelihood* (Maxver) e *Spectral Angle Mapper* (SAM), por região (*Bhattacharyya*) e baseada em objetos, quantificando as variações entre os resultados de cada classificador por meio de coeficientes de concordância total e por classe, destacando a capacidade identificação de alvos urbanos sobre imagens provenientes do satélite WorldView II, sobre três áreas teste localizadas na cidades satélites de Brasília, Sobradinho I e II. A classificação baseada em objetos foi a mais eficiente para mapear a cobertura de áreas urbanas, apresentando valores de exatidão global e índices Kappa e Tau superiores a 86%, apresentando superioridade aos métodos tradicionais.

ABSTRACT

Recent technological developments in remote sensing have made possible a large increase in the quality of the satellite images, supporting a clearer view of intra-urban environments. A notable example is the satellite WorldView II. Launched in 2009, its images became commercially available in 2010. This orbital Earth observation system delivers a 50cm resolution for the panchromatic band and 2m in its 8 spectral bands. Despite this extraordinary advance in terms of spatial and spectral resolutions, traditional image processing systems offer classification methods that suffer great influence of the multiplicity of features observed in high resolution images. An important source of these difficulties has to do with the limitations of pixel-based classifiers that only take in consideration the spectral information, since they cannot tackle satisfactorily the spectral variability of different urban targets. In search of a solution, a new class of software packages has emerge, which enable object-based image classification and facilitate the representation and processing of human knowledge associated to specific characteristics of the targets. However, most of those software packages with such characteristics are proprietary and of difficult access due to the high cost of their licenses. In this study, the objective was to evaluate the potentials and the accuracy of classifications generated by the pixel Maximum Likelihood (Maxver) and Spectral Angle Mapper (SAM) methodologies by region (Bhattacharyya) and object-based, quantifying the variations among the results of each classifier by means of overall and by class accuracy, highlighting the capacity of identifying the urban targets on images from the WorldView II satellite, using three area-tests located in the cities of Brasília, Sobradinho I and II. The classification based on objects was the most efficient to map urban area coverage, with overall accuracy values and Kappa and Tau indices above 87%, superior to the ones found in traditional methods.

LISTA DE SIGLAS E ABREVIATURAS

ENVI	Environment for Visualizing Images
ϵ_c^*	Erro de comissão
ϵ_o^*	Erro de omissão
e_p	Exatidão do produtor
e_u	Exatidão do usuário
GEOBIA	Geographic-Object-Based Image Analysis
K	Coeficiente de concordância Kappa
K_i	Kappa condicional;
MAX*	Classificação por pixel (Maxver)
MAXVER	Maxima Verossimilhanca
MNF	Minimum Noise Fraction
NDVI	Normalised Difference Vegetation Index
OBIA	Object-Based Image Analysis
OBJ*	Classificação baseada em objetos
PDI	Processamento Digital de Imagens
P_o	Exatidão Global
PPI	Pixel Purity Index
P_r	Concordância esperada
REG*	Classificação por região (Bhattacharyya)
SAM	Spectral Angle Mapper
SIG	Sistema de Informação Geográfica
SPRING	Sistema de Gerenciamento de Imagem Georreferenciadas
T	Coeficiente de concordância Tau
UTM	Universal Transversa de Mercator

*Abreviações e abreviações utilizadas somente para este trabalho.

SUMÁRIO

RESUMO.....	vi
ABSTRACT	vii
LISTA DE SIGLAS E ABREVIATURAS	viii
LISTA DE FIGURAS	xi
LISTA DE QUADROS	xvi
1 INTRODUÇÃO.....	1
2 OBJETIVOS	3
3 REVISÃO BIBLIOGRÁFICA	4
3.1 Sensoriamento Remoto.....	4
3.1.1 Imagens de alta resolução espacial	5
3.1.1.1 Satélite WorldView II.....	6
3.1.2 Classificação automática de imagens	7
3.1.2.1 Segmentação	8
3.1.2.2 Classificação por pixel Spectral Angle Mapper (SAM)	9
3.1.2.3 Classificação por pixel - Máxima Verossimilhança (Maxver)	11
3.1.2.4 Classificação por região – Bhattacharyya.....	13
3.1.2.5 Sistemas baseados em conhecimento	14
3.1.2.6 Classificação baseada em objeto	15
3.1.3 Sistemas para classificação de imagens.....	17
3.1.3.1 O sistema InterIMAGE.....	19
3.2 Qualidade de dados.....	20
3.2.1 Matriz de confusão	21
3.2.2 Padrão, unidade e número de amostras.....	23
3.2.3 Coeficientes de concordância	24
3.2.3.1 Exatidão Global	24
3.2.3.2 Coeficiente Kappa	25
3.2.3.3 Coeficiente Tau.....	26
3.2.3.4 Kappa Condicional	27
3.2.3.5 Exatidão do usuário e do produtor.....	28
4 MATERIAL E MÉTODOS	29
4.1 Área de estudo	29

4.1.1	Áreas-teste	29
4.2	Materiais utilizados.....	32
4.3	Métodos	33
4.3.1	Fase preparatória.....	34
4.3.2	Fase de classificações	37
4.3.3	Fase de avaliação das classificações.....	43
5	RESULTADOS E DISCUSSÃO.....	47
5.1	Segmentações	47
5.2	Regras de decisão para separação de classes no InterIMAGE	49
5.3	Redução da dimensão espectral por <i>Minimum Noise Fraction</i> (MNF) utilizada na classificação SAM	53
5.4	Mapas temáticos e avaliação das classificações	54
5.4.1	Comparação dos coeficientes de concordância total entre as classificações	73
5.4.2	Coeficientes de concordância por classe	75
5.4.2.1	Asfalto.....	76
5.4.2.2	Cobertura de Cerâmica Clara.....	78
5.4.2.3	Cobertura Cerâmica	80
5.4.2.4	Cobertura de Cimento Claro	82
5.4.2.5	Cobertura de Cimento Escuro.....	83
5.4.2.6	Cobertura de Cimento Médio	84
5.4.2.7	Cobertura de Cimento com Pigmentação Verde	86
5.4.2.8	Cobertura Metálica	88
5.4.2.9	Piscina.....	89
5.4.2.10	Solo Exposto.....	90
5.4.2.11	Sombra.....	91
5.4.2.12	Vegetação Arbórea	92
5.4.2.13	Vegetação Rasteira	94
6	CONCLUSÕES E RECOMENDAÇÕES	96
6.1	Recomendações e sugestões	98
6.2	Propostas para trabalhos futuros.....	98
7	REFERÊNCIAS BIBLIOGRÁFICAS	100

LISTA DE FIGURAS

Figura 1 - Resposta espectral das bandas do satélite WorldView II	6
Figura 2 - Gráfico dos espectros de referência (r) e do espectro do $pixel$ (t)	10
Figura 3 - Limite de aceitação de uma classificação Maxver	12
Figura 4 - Exemplos de distância euclidiana e distância de Bhattacharyya	14
Figura 5 - Esquema do processo de interpretação de uma cena no InterIMAGE	20
Figura 6 - Diferença de acurácia e precisão	21
Figura 7 - Localização da área de estudo e abrangência das regiões administrativas V e XXVI	29
Figura 8 - Localização das áreas-teste	30
Figura 9 - Localização de área-teste 1	30
Figura 10 - Localização de área-teste 2	31
Figura 11 - Localização de área-teste 3	32
Figura 12 - Esquema das etapas metodológicas do trabalho	33
Figura 13 - Amostras de treinamento coletadas sobre a imagem fusionada da área-teste 1 (classificação Maxver).....	37
Figura 14 - Visualização dos $pixels$ puros em espaço n-dimensional para a área-teste 1	38
Figura 15 - Estruturação de redes semânticas para as três áreas-teste	42
Figura 16 - Amostragem aleatória simples de pontos para área-teste 1	45
Figura 17 - Amostragem aleatória simples de pontos para área-teste 2	45
Figura 18 - Amostragem aleatória simples de pontos para área-teste 2	46
Figura 19 - Regras de decisão para as classes Cobertura de Cerâmica Clara (a) e Cobertura de Cerâmica (b)	50
Figura 20 - Regras de decisão para as classes Cobertura de Cimento Escuro (a) e Cobertura de Cimento Claro (b).....	50
Figura 21 - Regras de decisão para as classes Solo Exposto (a) e Cobertura de Cimento Verde (b)	50
Figura 22 - Regras de decisão para as classes Piscina (a) e Sombra (b)	50
Figura 23 - Regras de decisão para as classes Cobertura de Cimento Médio (a) e Cobertura Metálica (b).....	51
Figura 24 - Regras de decisão para as classes Vegetação Arbórea (a) e Vegetação Rasteira (b)	51

Figura 25 - Separação da classe Vegetação Rasteira das demais, através do fatiamento de histograma	52
Figura 26 - Separação da classe Cobertura de Cerâmica das demais, através do fatiamento de histograma	52
Figura 27 - Autovalores observados pela transformação MNF para dados do Worldview II na área-teste 1	53
Figura 28 - Componentes da transformação MNF da área-teste 1	54
Figura 29 - Mapa temático resultante da classificação por região (Bhattacharyya) para a área-teste 1	55
Figura 30 - Mapa temático resultante da classificação por região (Bhattacharyya) para a área-teste 2	57
Figura 31 - Mapa temático resultante da classificação por região (Bhattacharyya) para a área-teste 3	58
Figura 32 - Mapa temático resultante da classificação baseada em objeto para a área-teste 1	60
Figura 33 - Mapa temático resultante da classificação baseada em objeto para a área-teste 2	61
Figura 34 - Mapa temático resultante da classificação baseada em objeto para a área-teste 3	63
Figura 35 - Mapa temático resultante da classificação por <i>pixel</i> (Maxver) para a área-teste 1	64
Figura 36 - Mapa temático resultante da classificação por <i>pixel</i> (Maxver) para a área-teste 2	66
Figura 37 - Mapa temático resultante da classificação por <i>pixel</i> (Maxver) para a área-teste 3	67
Figura 38 - Mapa temático resultante da classificação por <i>pixel</i> (SAM) para a área-teste 1	69
Figura 39 - Mapa temático resultante da classificação por <i>pixel</i> (SAM) para a área-teste 2	70
Figura 40 - Mapa temático resultante da classificação por <i>pixel</i> (SAM) para a área-teste 3	72
Figura 41 - Coeficientes de concordância para a área-teste 1	74
Figura 42 - Coeficientes de concordância para a área-teste 2	74
Figura 43 - Coeficientes de concordância para a área-teste 3	74
Figura 44 - Coeficientes de concordância para a classe Asfalto	77
Figura 45 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Asfalto	77
Figura 46 - Espectro dos alvos: Asfalto (linha em preto) e Cobertura de Cimento Escuro (linha em vermelho)	78
Figura 47 - Coeficientes de concordância para a classe Cobertura de Cerâmica Clara	79
Figura 48 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Cobertura Cerâmica Clara	80

Figura 49 - Espectro dos alvos: Cobertura Cerâmica Clara (linha em preto), Cobertura Cerâmica (linha em vermelho) e Solo Exposto (linha em azul).....	80
Figura 50 - Coeficientes de concordância para a classe Cobertura Cerâmica.....	81
Figura 51 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Cobertura de Cerâmica	81
Figura 52 - Coeficientes de concordância para a classe Cobertura de Cimento Claro.....	82
Figura 53 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Cobertura de Cimento Claro.....	83
Figura 54 - Espectro dos alvos: Cobertura de Cimento Claro (linha em preto) e Cobertura de Cerâmica Clara (linha em vermelho).....	83
Figura 55 - Coeficientes de concordância para a classe Cobertura de Cimento Escuro	84
Figura 56 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Cobertura de Cimento Escuro	84
Figura 57 - Coeficientes de concordância para a classe Cobertura de Cimento Médio	85
Figura 58 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Cobertura de Cimento Médio	85
Figura 59 - Espectro dos alvos: Cobertura de Cimento Médio (linha em preto) e Asfalto (linha em vermelho).....	86
Figura 60 - Coeficientes de concordância para a classe Cobertura Cimento Verde	87
Figura 61 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Cobertura de Cimento Verde.....	87
Figura 62 - Coeficientes de concordância para a classe Cobertura Metálica	88
Figura 63 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Cobertura Metálica	88
Figura 64 - Espectro dos alvos: Cobertura de Cimento Médio (linha em preto) e Cobertura Metálica (linha em vermelho).....	89
Figura 65 - Coeficientes de concordância para a classe Piscina	90
Figura 66 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Piscina.....	90
Figura 67 - Coeficientes de concordância para a classe Solo Exposto.....	91
Figura 68 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Solo Exposto	91
Figura 69 - Coeficientes de concordância para a classe Sombra.....	92

Figura 70 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Sombra.....	92
Figura 71 - Coeficientes de concordância para a classe Vegetação Arbórea.....	93
Figura 72 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Vegetação Arbórea.....	94
Figura 73 - Coeficientes de concordância para a classe Vegetação Rasteira.....	94
Figura 74 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Vegetação Rasteira.....	95
Figura 75 - Espectro dos alvos: Vegetação Rasteira (linha em preto) e Vegetação Arbórea (linha em vermelho).....	95

LISTA DE TABELAS

Tabela 1 - Bandas adicionais do Worldview II	6
Tabela 2 - Sistemas de processamento digital de imagens - PDI	17
Tabela 3 - Estrutura de uma matriz de confusão	22
Tabela 4 - Qualidade da classificação associada ao índice <i>Kappa</i>	26
Tabela 5 - Tamanho das amostras para cada classificação	44
Tabela 6 - Parâmetros utilizados para a segmentação das classes da área-teste 1	48
Tabela 7 - Parâmetros utilizados para a segmentação das classes da área-teste 2	48
Tabela 8 - Parâmetros utilizados para a segmentação das classes da área-teste 3	49
Tabela 9 - Valores de pertinência de cada classe para cada área-teste	52
Tabela 10 - Matriz de confusão da classificação por região (Bhattacharyya) para a área-teste 1	56
Tabela 11 - Matriz de confusão da classificação por região (Bhattacharyya) para a área-teste 2	57
Tabela 12 - Matriz de confusão da classificação por região (Bhattacharyya) para a área-teste 3	59
Tabela 13 - Matriz de confusão da classificação baseada em objeto para a área-teste 1	60
Tabela 14 - Matriz de confusão da classificação baseada em objeto para a área-teste 2	62
Tabela 15 - Matriz de confusão da classificação baseada em objeto para a área-teste 3	63
Tabela 16 - Matriz de confusão da classificação por <i>pixel</i> (Maxver) para a área-teste 1	65
Tabela 17 - Matriz de confusão da classificação por <i>pixel</i> (Maxver) para a área-teste 2	66
Tabela 18 - Matriz de confusão da classificação por <i>pixel</i> (Maxver) para a área-teste 3	68
Tabela 19 - Matriz de confusão da classificação por <i>pixel</i> (SAM) para área-teste 1	69
Tabela 20 - Matriz de confusão da classificação por <i>pixel</i> (SAM) para a área-teste 2	71
Tabela 21 - Matriz de confusão da classificação por <i>pixel</i> (SAM) para a área-teste 3	72
Tabela 22 - Coeficientes de concordância calculados para as três áreas-teste	73
Tabela 23 - <i>Kappa</i> condicional de cada classe das três áreas-teste	75
Tabela 24 - Exatidão do Usuário de cada classe das três áreas-teste	75
Tabela 25 - Exatidão do Produtor de cada classe das três áreas-teste	76

LISTA DE QUADROS

Quadro 1 - Classes identificadas na imagem Worldview II.....	34
Quadro 2 - Combinações de similaridade e área para área-teste 1.....	39
Quadro 3 - Exemplos de amostras de treinamento para classificação por região Bhattacharyya para área-teste 1	40
Quadro 4 - Combinações de similaridade e área encontradas para cada área-teste	47

1 INTRODUÇÃO

Uma das principais fontes de dados para mapeamentos de uso e cobertura do solo são imagens orbitais de sensoriamento remoto. Entretanto, até meados da década de 1990 não existiam imagens com resolução espacial suficiente para identificar e mapear alvos em ambientes urbanos. Assim, a fotogrametria foi, por muito tempo, a única fonte de dados para este tipo de estudo. Porém, o alto custo para obtenção das fotografias aéreas, aliado as suas limitações de resolução espectral, impediram a produção em larga escala de estudos mais detalhados de áreas urbanas.

O lançamento do satélite Ikonos II, em 1999, deu início a uma onda de lançamentos de novos satélites capazes de produzir imagens de alta resolução espacial com bandas em diferentes faixas do espectro eletromagnético, o que trouxe grandes inovações para estudos que envolvam mapeamentos de espaços urbanos.

As técnicas de sensoriamento remoto contam, atualmente, com a utilização de modernas plataformas aéreas e orbitais capazes de produzir imagens multi e hiperespectrais de alta resolução espacial, temporal e radiométrica aumentando a capacidade de discriminar, cada vez melhor, os alvos da superfície terrestre e ampliando significativamente o leque de aplicações, representando um importante suporte para a solução de problemas em diversas áreas, tais como cadastro urbano, cadastro rural, planejamento e gestão ambiental, entre outros.

Esta evolução permitiu o aumento da utilização de dados de sensoriamento remoto em áreas urbanas, o que tem contribuído para pesquisas no tema, acerca da criação de novas abordagens metodológicas e melhorias em metodologias já existentes, otimizando a extração de informações de imagens.

Um grupo importante destas metodologias está relacionado com a classificação de imagens, que consiste no reconhecimento de padrões espectrais e espaciais permitindo a geração de classes informacionais.

Com a nova geração de sistemas de sensores, os classificadores tradicionais, tais como “*pixel a pixel*” e por regiões, vêm sendo alvo de diversos estudos comparativos (Pinho *et al.* 2005; Arcoverde *et al.* 2010; Bernardi *et al.* 2007; Zanardo *et al.* 2009; Xiaoxia *et al.* 2005; AL-Ahmadi & Hames, 2009; Kamagata *et al.* 2005), pois o elevado grau de detalhes em imagens de alta resolução apresenta uma grande confusão espectral causada pela repetição de alvos naturais e sintéticos, pela complexidade e heterogeneidade causadas por tamanho e formas diversas, e composições variadas. Estas características tornam a variação espectral um

fator significativo dentro de um ambiente urbano, surgindo a necessidade de abordagens que levem em consideração outros atributos, além das características espectrais dos *pixels*. Bias *et al.* (2009) afirmam que um horizonte para tais problemas seriam pesquisas voltadas à lógica *Fuzzy*, geometria de fractais, videografia e a combinação de interpretações *Fuzzy* e de fractais com as redes neurais.

Dentre essas alternativas de classificadores de imagens de alta resolução espacial, a metodologia de análise geográfica de imagens baseada em objeto GEOBIA (*Geographic Object-Based Image Analysis*) (Hay & Castilla 2008) vem ganhando importância nos últimos anos. Ela surge como um significativo avanço nos processos de classificação automática de imagens orbitais, já que possibilita a modelagem do conhecimento humano referente a características específicas dos alvos, como brilho, textura, formato, contexto, tamanho, relações de vizinhança, entre outros, tendo como foco a classificação de segmentos de imagem em vez de *pixels* isolados.

As informações extraídas a partir dessa abordagem representam um importante suporte para auxiliar no planejamento e gestão, principalmente de áreas urbanas, auxiliando em trabalhos que necessitem de dados de localização, distribuição e expansão urbana, além da possibilidade do monitoramento temporal de mudanças no uso e cobertura do solo.

2 OBJETIVOS

Este trabalho tem como objetivo geral avaliar as potencialidades e a acurácia dos classificadores para identificação de alvos urbanos em imagens de alta resolução espacial.

Para atingir esse objetivo, os seguintes objetivos específicos foram propostos:

- Avaliar a qualidade das classificações geradas pelas metodologias “*pixel a pixel*”, por região (Bhattacharyya) e baseada em objetos, verificando as vantagens de cada uma delas; e
- Quantificar as variações entre os resultados de cada classificador, por meio dos índices de Exatidão Global, *Kappa* e *Tau*, para avaliar a confiabilidade dos resultados de forma global e por meio dos índices de *Kappa* Condicional, Exatidão do usuário e do produtor para avaliar a confiabilidade dos resultados por classes.

3 REVISÃO BIBLIOGRÁFICA

3.1 Sensoriamento Remoto

No decorrer das últimas quatro décadas, o planeta Terra começou a ser olhado e vistoriado por sensores imageadores que, praticamente, capturam tudo que está presente na superfície terrestre ou que nela está se modificando. Isso está sendo feito com o explícito objetivo de se obter imagens periódicas que possibilitem o monitoramento do meio ambiente em uma escala global e a obtenção de melhores informações acerca dos recursos naturais renováveis e não renováveis (MENESES & ALMEIDA, 2012).

Shimabukuro (1996) aponta que a necessidade do ser humano de ler o seu entorno, coletando cada vez mais informações com maior precisão sobre a relação de suas atividades socioeconômicas com a natureza, tem motivado o desenvolvimento contínuo do sensoriamento remoto e de suas ferramentas para mapear e monitorar os recursos naturais.

Segundo Jensen (2000), sensoriamento remoto é a arte e a ciência da obtenção de informação sobre um objeto, sem contato físico direto. A tecnologia científica pode ser usada para medir e monitorar importantes características biofísicas e atividades humanas. Silva (2001) afirma que esta tecnologia pode registrar informações em condições de campo, aerotransportados ou colocados em plataformas orbitais. Quando colocados em plataformas orbitais, os dados coletados apresentam algumas vantagens em relação àqueles coletados no campo ou aerotransportados. Os sensores orbitais permitem obter uma visão ampla e periódica da área imageada.

A grande diversidade de sensores possibilita a obtenção de imagens com diferentes características, as quais se adaptam às mais diversas aplicações do sensoriamento remoto. Para que a dinâmica dos alvos terrestres possa ser observada e monitorada adequadamente, um dos aspectos relevantes do sensoriamento remoto é a frequência temporal com que as imagens são adquiridas pelos sensores a bordo de satélites. A análise combinada de imagens adquiridas por diferentes sensores/satélites em aplicativos de processamento de imagens e em Sistemas de Informação Geográfica (SIG) é uma alternativa viável para aumentar a frequência de observação dos alvos (MOREIRA *et al.*, 2005).

Meneses & Almeida (2012) afirmam que, atualmente, há em circulação no espaço dezenas de sensores orbitais imageando a superfície da Terra em todas as faixas espectrais possíveis, com os mais variados parâmetros de resoluções espacial, espectral, radiométrica e

temporal. De um lado há os sensores hiperespectrais, com centenas de bandas espectrais, e de outro há os sensores capazes de detectar objetos, menores que 50 cm, na superfície da Terra, denominados sensores de alta resolução espacial.

3.1.1 Imagens de alta resolução espacial

De acordo com Jacobsen (2003), o uso de sensores de alta resolução espacial para o mapeamento civil abriu um novo campo de aplicações. Por muito tempo os sensores espaciais de alta resolução foram limitados para uso militar, mas, com o fim da guerra fria, a situação mudou. Estes sensores ganharam várias versões comerciais, fazendo com que a competição reduzisse seus preços, tornando as imagens mais acessíveis.

Esse novo cenário abriu o horizonte para aplicações de sensoriamento remoto em áreas urbanas, pois esses sensores reúnem a alta resolução espacial das fotografias aéreas e dos sensores aerotransportados com a alta resolução temporal de sensores orbitais. Além disso, esses novos sensores também possuem alta resolução radiométrica, o que possibilita uma melhor discretização entre os alvos urbanos (PINHO, 2006).

Além disso, ainda há os sensores de altíssima resolução espacial, como o GeoEye-1, anteriormente conhecido como OrbView-5, que conta com uma imagem pancromática de 41 cm de resolução espacial, e o seu “irmão” o GeoEye-2, com lançamento previsto para este ano, que proporcionará uma resolução espacial de 25 cm. Sensores como estes potencializam a capacidade de análise geoespacial em qualquer campo, uma vez que fornecem uma compreensão clara do mundo.

Para estudos em áreas urbanas, tão importante quanto a resolução espacial é a resolução espectral. Jensen (2009) aponta para a importância da soma da resolução espacial com a espectral para áreas urbanas, já que a união destas características permite, além de uma maior proximidade visual com o mundo real, a exploração de feições, com identificação possível apenas em determinados comprimentos de onda. Até então sensores como Ikonos, Quickbird-2, Kompsat-2, GeoEye-1, apesar de serem considerados de alta resolução espacial, possuíam apenas quatro bandas espectrais, o que limitava sua capacidade de exploração em áreas urbanas, devido à complexidade dos alvos.

3.1.1.1 Satélite WorldView II

O WorldView II, lançado em outubro de 2009, é o primeiro satélite de alta resolução (pancromático de 0,46 m e multiespectral de 1,84 m) a contar com 8 bandas em diferentes faixas do espectro eletromagnético (Figura 1). Opera a uma altitude de 770 km, tem 46 cm de resolução pancromática e 1,85 m de resolução multiespectral. Com uma resolução radiométrica de 11 bits, tem um tempo médio de revisita de 3,7 dias 20° off nadir e é capaz de coletar até 1 milhão de km² de imagens por dia (DIGITAL GLOBE, 2010a).




Figura 1 - Resposta espectral das bandas do satélite WorldView II

Fonte: Adaptado de Digital Globe (2010b).

Além da capacidade de discriminação dos alvos proporcionados pelas bandas no comprimento do azul, verde, vermelho e infravermelho próximo, comum na maioria dos sensores, o satélite WorldView II conta, ainda, com outras quatro bandas (Tabela 1).

Tabela 1 - Bandas adicionais do Worldview II

Banda	Comp. de onda nm	Característica
<i>Coastal Blue</i>	400-450	Tem o papel de melhorar as técnicas de correção atmosférica e auxilia na realização de análise de vegetação e é muito útil em estudos batimétricos, já que é pouco absorvida pela água.
<i>Yellow</i>	585-625	Importante na detecção de alguns tipos de vegetações específicas, já que detecta o amarelo, tanto em terra como na água.
<i>Red-Edge</i>	705-745	Estrategicamente posicionada no espectro, essa banda é excelente para detectar a saúde das vegetações.
<i>Near Infrared 2</i>	860-1040	Sobrepõe a banda <i>Near Infrared 1</i> , mas é menos afetada pela influência atmosférica, permitindo uma análise mais ampla da vegetação e estudos de biomassa.

Fonte: Adaptado de Digital Globe (2010b).

Além disso, vários estudos vêm encontrando novas aplicações para as bandas do sensor: Carvalho (2011), Ribeiro *et al.* (2011), Souza (2005), Kux e Souza (2012) e Pinho *et al.* (2005) realizaram testes com o Worldview II com o objetivo de efetuar mapeamento de cobertura do solo em áreas urbanas. Souza *et al.* (2005) realizaram estudos verificando a contribuição das novas bandas espectrais do satélite Worldview II para a classificação de tipos de vegetais em *habitats* costeiros. Zengeya *et al.* (2013) realizaram estudos verificando a contribuição das novas bandas espectrais do satélite para estimar a qualidade da forragem (concentração de nitrogênio), afim de explicar a distribuição de gado em uma pastagem. Eckert (2012) e Mutanga *et al.* (2012) trabalharam com estimativa de biomassa florestal usando índice de vegetação por diferença normalizada (NDVI) e medidas de textura do Worldview II. Mutanga *et al.* (2012), Pu & Landry (2012) e Immitzer *et al.* (2012) utilizaram as novas bandas espectrais do satélite Worldview II para análise espectral da vegetação e identificação de espécies de árvores em áreas urbanas.

3.1.2 Classificação automática de imagens

Classificação é o processo de extração de informação em imagens para reconhecer padrões e objetos homogêneos. Os métodos de classificação são usados para mapear áreas que apresentam um mesmo significado em imagens de satélite (KÖRTING, 2006).

Segundo Liotte & Macedo (2000), o objetivo da classificação é a substituição da análise visual da imagem por técnicas de identificação automática de feições da cena. Com isso, os valores de refletância de cada *pixel* são agrupados em classes com valores similares. Este agrupamento em classes de padrões de respostas similares envolve a análise de dados multiespectrais e a aplicação de regras de decisão baseadas em estatísticas.

De acordo com Bernardes *et al.* (2005), duas abordagens distintas são adotadas na classificação automática de imagens: classificação supervisionada e não supervisionada. A classificação supervisionada é realizada utilizando como base um conjunto de amostras de treinamento coletado pelo analista. Quando não for possível definir áreas representativas para o treinamento, podem ser utilizados algoritmos baseados em regras estatísticas capazes de fazer o reconhecimento das classes presentes na imagem, o que configura uma classificação não supervisionada.

Os algoritmos utilizados para classificação de imagens, como o K-Means e Isodata, (não supervisionados); Máxima Verossimilhança (Maxver), Distância Mínima, Paralelepípedo,

Distância Mahalanobis e Spectral Angle Mapper (SAM) (supervisionados) utilizam a classificação "pixel a pixel" (BERNARDI, 2007). Já algoritmos como Ioseg, Battacharya e ClaTex são métodos de classificação por regiões, isto é, procuram simular o comportamento de um foto-intérprete ao reconhecer áreas homogêneas de imagens, baseado em suas propriedades espectrais e espaciais (KÖRTING, 2006).

Conceitualmente, pode-se incluir o processo de segmentação como sendo um procedimento de análise baseada em objeto (OBIA), em razão deste processo não levar em consideração apenas o valor digital do pixel a ser classificado, mas também dos pixels ao seu redor, procurando por similaridades e avaliação estatística o agrupando destes conjuntos que passam a caracterizar as diversas feições a serem mapeadas.

No entanto, no presente trabalho, objetivando uma estruturação mais didática das análises a serem efetuados, optou-se por efetuar a separação dos processos de classificação (pixel a pixel, segmentação e orientação a objetos), não incluindo a segmentação como sendo orientação a objeto (OBIA) e, estabelecendo este critério a partir do surgimento de softwares específicos que atuam não só na segmentação, mas também na avaliação de características como: forma, textura, área e parâmetros espectrais.

Sendo assim na análise baseada em objeto, toma-se por base o objeto na imagem e não apenas sobre o pixel. Assim, na imagem, um objeto representa uma entidade que pode ser individualizada, tem atributos próprios e as mesmas propriedades da classe que lhe deu origem (DEFINIENS, 2004).

É importante destacar que os métodos citados (classificação por regiões e OBIA) necessitam de segmentos da imagem, definidos em etapa anterior à classificação, como dados de entrada. Esse procedimento influencia diretamente na qualidade desses métodos.

3.1.2.1 Segmentação

A segmentação é um importante processo na análise de imagens de sensoriamento remoto, este processo consiste em subdividir uma imagem em regiões homogêneas, considerando algumas de suas características intrínsecas, como, por exemplo, o nível de cinza dos *pixels* e a textura que melhor representam os objetos presentes na cena (OLIVEIRA & SILVA, 2005).

Dlugosz *et al.* (2005) afirmam que, por meio do processo de segmentação, é possível obter, de maneira rápida, a discriminação e a delimitação de fragmentos. Os polígonos gerados

pela segmentação e posteriormente convertidos para vetor podem ser usados como amostras de treinamento em futuras classificações digitais e, ainda, em classificações visuais por meio de simples atribuição de classes.

De acordo com Ferreira (2011), os algoritmos de segmentação são geralmente baseados em uma de duas propriedades básicas: descontinuidades e similaridades. Na primeira categoria, a ideia é dividir a imagem levando em consideração variações abruptas na intensidade dos *pixels*. Na segunda, a abordagem é particionar a imagem em regiões que são similares de acordo com algum critério. O autor ainda destaca a relevância do método de segmentação por regiões, já que este produz objetos com bordas bem definidas e mostra-se robusto a imagens tomadas em condições diversas de iluminação, ruído etc. Os métodos de segmentação por regiões mais utilizados são: Divisor de Águas (Watershed) e Crescimento de Regiões.

A escolha do critério de limiar de similaridade e do tamanho mínimo para os polígonos que serão gerados está intimamente relacionada com o problema a ser solucionado, com o tipo de imagem analisada e com a classe de objetos-alvo que se deseja encontrar (FERREIRA, 2011). Segundo Meneses & Almeida (2012), esse processo, inevitavelmente, acaba levando a procedimentos de tentativa e erro até que se consiga uma configuração apropriada dos segmentos gerados. Essa tarefa se torna mais complexa na medida em que mais heterogênea for a área de estudo. Por exemplo, a segmentação de áreas urbanas, onde normalmente pretende-se obter muitas categorias diferentes no processo de classificação, é um exemplo da variedade de possibilidades que se tem para a geração de polígonos, dependendo, naturalmente, dos limiares de similaridade estabelecidos.

Muitos critérios podem ser definidos e, na verdade, existe uma gama razoável de diferentes implementações disponíveis, dentre elas estão as metodologias de homogeneidade intrarregiões adotadas pelo segmentador do *software* Spring descrito por Bins *et al.* (1996) e a metodologia de Segmentação Multirresolução, proposto por Baatz & Schäpe (2000), ambos segmentadores de Crescimento de Regiões.

3.1.2.2 Classificação por *pixel Spectral Angle Mapper* (SAM)

Classificadores *pixel a pixel* utilizam apenas a informação espectral do *pixel* para encontrar sua classe mais provável, traçando uma probabilidade de um determinado *pixel* pertencer ou não a uma determinada classe.

O algoritmo SAM, descrito por Kruse *et al.* (1993), faz uma classificação espectral determinando a similaridade entre dois espectros por meio do cálculo do ângulo formado entre

eles, tratando-os como vetores em um espaço de dimensionalidade igual ao número de bandas. O ângulo entre os dois vetores constitui o ângulo espectral “ α ” cujo valor é inversamente proporcional à similaridade espectral entre os espectros (Figura 2). O algoritmo SAM generaliza essa interpretação geométrica para o espaço n dimensional.




Figura 2 - Gráfico dos espectros de referência (r) e do espectro do *pixel* (t)
Fonte: Adaptado de Kruse *et al.*, 1993.

O espectro de referência pode referir-se a uma biblioteca espectral extraída no laboratório ou campo (por meio de um espectroradiômetro) ou até mesmo amostras de pixels extraídas da própria imagem. Para cada espectro de referência, o classificador SAM gera uma imagem, denominada rule image, cujos pixels representam individualmente tais ângulos e quanto menor é o valor do pixel, maior é a probabilidade de ele ser composto pela amostra de referência. As imagens rules geradas podem ser representadas em uma composição colorida, permitindo analisar os resultados de cada um dos espectros de referência classificado (PEDROSA, 2010).

De acordo com Kruse et al. (1993), o classificador SAM utiliza o arco-cosseno do coeficiente de correlação não normalizado, cuja formulação matemática é expressa pela equação 3.1.

$$\alpha = \cos^{-1} \left(\frac{\sum_{i=1}^n t_i r_i}{\sqrt{\sum_{i=1}^n t_i^2 \sum_{i=1}^n r_i^2}} \right), \text{ onde:} \quad (3.1)$$

α = ângulo formado entre o espectro de referência e o espectro de imagem;

n = número de bandas;

r = espectros de referência; e
 t = espectro do *pixel*.

O ângulo α , determinado pelo \cos^{-1} , apresenta uma variação entre 0 e 90. Carvalho Júnior & Meneses (2000) mostram que a equação acima pode também ser expressa como cosseno de α (Equação 3.2).

$$\cos \alpha = \left(\frac{\sum_{i=1}^n t_i r_i}{\sqrt{\sum_{i=1}^n t_i^2 \sum_{i=1}^n r_i^2}} \right) \quad (3.2)$$

Neste caso, a melhor estimativa adquire valores próximos de 1.

3.1.2.3 Classificação por *pixel* - Máxima Verossimilhança (Maxver)

De acordo com Lopes (2006), a técnica Maxver considera a ponderação das distâncias entre médias dos níveis digitais das classes, utilizando parâmetros estatísticos. Para que esta classificação seja precisa é necessário um número razoavelmente elevado de *pixels* para cada conjunto de treinamento. A partir dos conjuntos de treinamento pode ser gerado o diagrama de dispersão das classes e estimadas nas distribuições de probabilidade, considerando a distribuição Gaussiana (distribuição normal) para cada classe do treinamento.

Para duas classes com distribuição de probabilidade distintas, as distribuições representam a probabilidade de um *pixel* pertencer a uma ou outra classe, dependendo da sua posição em relação a esta distribuição. Ocorre uma região onde as duas curvas sobrepõem-se, indicando que um determinado *pixel* tem igual probabilidade de pertencer às duas classes. Nesta situação estabelece-se um critério de decisão a partir da definição de limiares. A figura 3 representa o limite de aceitação de uma classificação, no ponto onde as duas distribuições se cruzam. Um *pixel* localizado na área em cinza, apesar de pertencer à classe 2, será classificado como classe 1 (INPE, 2008).

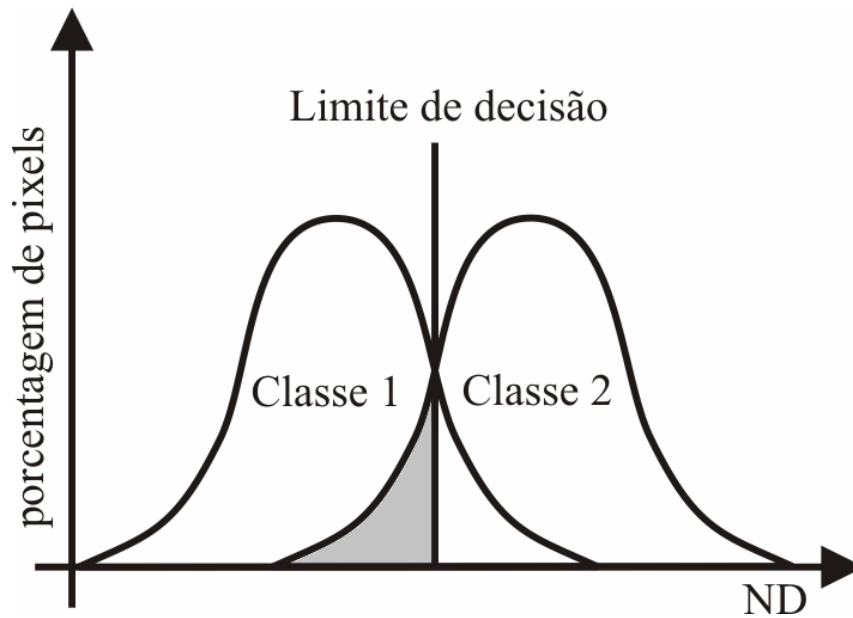


Figura 3 - Limite de aceitação de uma classificação Maxver

Portanto, na classificação Maxver, cada *pixel* é destinado à classe que tem a mais alta probabilidade, isto é, a máxima verossimilhança. Isso significa que para um *pixel* na posição x do espaço multiespectral, um conjunto de probabilidades é computado e fornece a possibilidade relativa do *pixel* pertencer a cada classe disponível $p(\omega_i|x)$ (MENESES & ALMEIDA, 2012).

Segundo Richards & Jia (2006), as classes espectrais para uma imagem ser representada pelo Teorema de Bayes podem ser expressas pela equação (3.3).

$$p(\omega_i|x), i = 1, \dots, M, \text{ onde:} \quad (3.3)$$

p : probabilidade;

ω : classe;

x : posição do *pixel*; e

M : número total de classes.

Desta forma, um *pixel* x pertencerá à classe ω_i se a probabilidade que associa o *pixel* a esta classe for maior do que a probabilidade que associa o *pixel* a outra classe. Assim, $p(\omega_i|x)$ fornece a probabilidade de que a classe correta é ω_i para um *pixel* na posição x (RICHARDS & JIA, 2006), de acordo com a equação (3.4).

$$x \in \omega_i \text{ se } p(\omega_i|x) > p(\omega_j|x), \text{ onde } i \neq j \quad (3.4)$$

3.1.2.4 Classificação por região – Bhattacharyya

Segundo Meneses & Almeida (2012), a classificação por região se dá, inicialmente, pela utilização de um algoritmo de segmentação que ao definir regiões homogêneas na imagem prepara-a para uma classificação posterior com base nessas regiões e não com base em valores individuais dos *pixels*.

De acordo com Kury & Vieira (2002), a classificação por região é um método alternativo que provê um meio dentro do qual a variabilidade espacial e a textura natural podem ser usadas no processo de classificação. Ao invés de considerar as características espectrais do *pixel* no processo de decisão, um agrupamento de *pixels* é selecionado e usado como unidade de classificação.

Segundo Oliveira *et al.* (2003), para obter uma boa classificação baseada em regiões é imprescindível uma boa segmentação dos alvos de interesse. Classificadores por região procuram simular o comportamento de um foto-intérprete, ao reconhecer áreas homogêneas de imagens, baseados nas suas propriedades espectrais e espaciais. A informação de borda é utilizada inicialmente para separar cada região (KÖRTING, 2006).

As técnicas de classificação por região podem ser divididas em supervisionada e não supervisionada, neste caso seguem os mesmos princípios da classificação *pixel a pixel*.

Dentre os classificadores por região, o *software* Spring, por exemplo, possui o Ioseg, Bhattacharyya e ClaTex. O Idrisi apresenta a solução de classificação por região a partir de sua versão *Taiga* e o Envi, até a versão 4.7, não apresenta um módulo específico para classificação por região (MENESES & ALMEIDA, 2012).

A classificação Bhattacharyya utiliza amostras de alguns segmentos para treinar o classificador, calculando a média e a matriz de covariância de cada classe. Em seguida, cada segmento é alocado em uma dessas classes, segundo a menor distância de Bhattacharyya (CORREIA *et al.*, 2007).

Para um melhor entendimento da distância de Bhattacharyya, Meneses e Almeida (2012) destacam que esta não é uma distância euclidiana, a qual na matemática é representada pela distância entre dois pontos, e sim uma distância calculada a partir da análise das médias e das covariâncias das amostras, como pode ser visto na figura 4, onde as amostras 1 e 3 seriam as mais próximas pela distância euclidiana (esquerda). Porém, pela distância de Bhattacharyya, as amostras 1 e 2 é que são mais próximas, ou seja, apresentam menor distância de Bhattacharyya, pois têm médias e covariâncias mais próximas (direita).

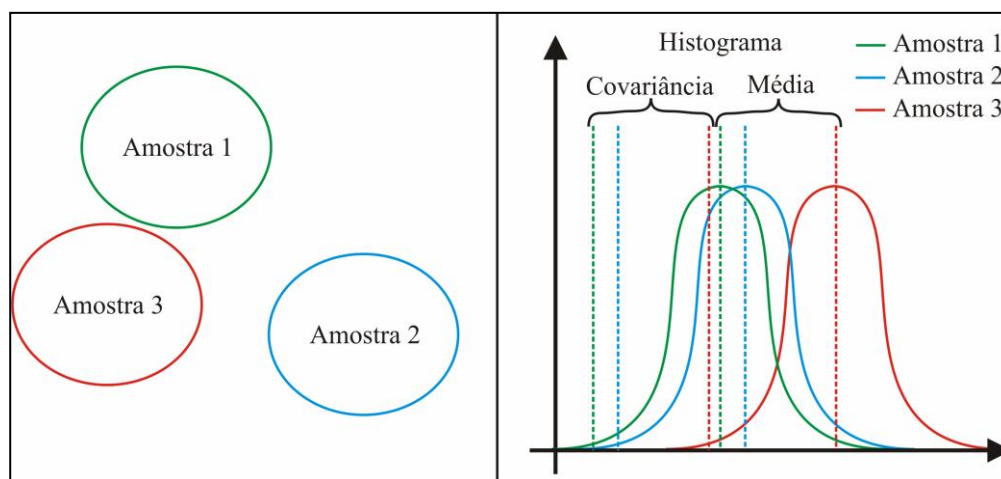


Figura 4 - Exemplos de distância euclidiana e distância de Bhattacharyya
Fonte: Adaptado de Meneses e Almeida (2012).

3.1.2.5 Sistemas baseados em conhecimento

Para Pahl (2008), em sistemas de análise de imagens baseados em conhecimento, a interpretação da imagem pode ser representada por meio de dois tipos de conhecimento: o conhecimento implícito, que está contido diretamente no código de um programa e descreve um rígido plano de procedimento, e o conhecimento explícito, que ocorre quando se conhecem as soluções alternativas para uma dada tarefa para a qual o sistema deve escolher uma função adequada e estas soluções estão indicadas explicitamente.

Para Feitosa (2005), esses sistemas procuram modelar, em um ambiente computacional, o conhecimento do foto-intérprete e inserir sua capacidade de combinar dados de diferentes fontes e diferentes formatos no processo de classificação de imagens de sensores remotos. Tais sistemas buscam reproduzir em um computador o raciocínio do foto-intérprete, de modo a realizar automaticamente grande parte da tarefa que, nos sistemas convencionais, fica a cargo do operador humano.

De acordo com Pinho (2005), a utilização desses sistemas abre um novo horizonte para a extração automática de informações de imagem de sensores remotos. Enquanto algoritmos de classificação têm como objetivo distinguir grupos de *pixels* com características semelhantes, os quais muitas vezes não se traduzem em objetos reais, na abordagem baseada em conhecimento o objetivo é identificar objetos que tenham uma existência concreta no mundo real e que expressem características de cor, forma, textura, padrão e contexto na imagem analisada.

Definiens (2004) descreve os passos para realizar uma interpretação baseada nesses sistemas, onde, inicialmente, o analista deve estruturar uma rede semântica e hierárquica, em seguida gerar elementos de análise de procedimento geralmente realizados por um processo de

segmentação, e, por fim, descrever as classes quanto aos atributos, limiares, funções de pertinência *Fuzzy* e regras de agregação dos valores de pertinência.

Assim, sistemas de interpretação de imagens baseados em OBIA, como o *Definiens Developer* e o *InterIMAGE* (COSTA et al. 2008; COSTA et al. 2010), se utilizam destas formas de representação do conhecimento e estratégia de análise de diferentes maneiras, mas sob a mesma lógica subjacente. Ou seja, o conhecimento implícito está presente nos algoritmos de processamento de imagens (segmentação e classificação, basicamente) e o conhecimento explícito encontra-se na forma de redes semânticas e hierárquicas, no caso do *Definiens Developer*, e de redes semânticas e regras de decisão no *InterIMAGE* (NOVACK, 2009).

3.1.2.6 Classificação baseada em objeto

Navulur (2006) define objeto como um conjunto de *pixels* de semelhantes propriedades espectrais e espaciais. Assim, a aplicação da OBIA refere-se à análise da imagem no espaço dos objetos e não no espaço de *pixels*, desta forma, os objetos são usados como dados de entrada para classificação de imagem, em vez de *pixels*. Conforme apresentado no item 3.1.2.1, a segmentação da imagem é a principal técnica utilizada para converter uma imagem em objetos. Um objeto tem, além de valores espectrais, formas, tamanhos, texturas, contextos, dentre outros atributos que podem ser utilizados no processo de classificação por meio da modelagem destes conhecimentos.

Segundo Pinho *et al.* (2005), a análise baseada em objetos requer um procedimento preliminar de segmentação para a criação destes, que, na prática, constitui o reconhecimento de objetos do mundo real representados na imagem, fazendo com que o número de elementos a serem interpretados no processo de classificação se reduza drasticamente (VIEIRA, 2010). A segmentação da imagem em diferentes escalas permite a criação de uma rede hierárquica com diferentes níveis de detalhes, permitindo o relacionamento de objetos maiores (superobjetos) com objetos menores (subobjetos) (TORRIJOS CADENA, 2011).

De acordo com Antunes (2003), a orientação a objeto na imagem pode ser entendida como a análise da relação de um objeto com os seus objetos vizinhos. Desta forma, de acordo com Definiens (2003), existem algumas premissas que devem ser consideradas na análise orientada a objetos:

- a caracterização dos objetos da imagem não pode se restringir apenas a atributos espectrais, pois estes muitas vezes não conseguem delimitar objetos complexos, sendo

necessária a inserção do conhecimento do analista no sistema de classificação da imagem;

- os objetos de interesse a serem extraídos de uma determinada cena podem estar associados a diferentes níveis de escalas, que devem estar representadas no processo de classificação. Assim, em uma cena de um ambiente, existem pequenos alvos, como casas, por exemplo, que se relacionam a um nível mais detalhado de escala, e áreas industriais com grandes construções, que se relacionam em uma menor escala; e
- a descrição do espaço de atributos de uma determinada classe pode ser imprecisa, o que introduz incertezas na associação de um objeto a determinada classe.

Segundo Pinho (2006), a materialização destas premissas é dada pelos procedimentos de segmentação de multirresolução, citados no item 3.1.2.1, e pela estruturação das classes em uma rede semântica.

A abordagem baseada em objetos favorece a estruturação das classes em uma rede semântica que permite a inserção de informações cognitivas no processo de classificação, que pode estruturada de forma hierárquica. Desse modo, é possível a criação de uma rede semântica hierárquica, que permite, de forma progressiva, que sejam atribuídas classes aos objetos (LUIZ *et al.*, 2009).

A vantagem da classificação baseada em objeto é que o usuário pode isolar objetos e explorar, juntamente com informações espectrais, propriedades espaciais, como a área do objeto, o comprimento, a largura e direção, entre outros, ou seja, a técnica permite que o usuário tire proveito de todas as dimensões de sensoriamento remoto. Navulur (2006) apresenta algumas vantagens da abordagem baseada em objetos, explorando estas dimensões:

- espectrais: bandas multiespectrais, incluindo banda pancromática;
- espacial: área, comprimento, largura, direção;
- textural: variação dos valores espectrais;
- morfológicas: parâmetros de forma, textura;
- contextual: relações com os vizinhos, análise de proximidade;
- incorpora atuais métodos comprovados/técnicas utilizadas para a análise de imagem, tais como classificação supervisionada e lógica *Fuzzy*, e é baseado em regras de classificação;
- incorpora algumas das funcionalidades GIS para a classificação temática, incluindo o uso de informações auxiliares, dados vetoriais, medidas de distância etc.; e
- extrai características da mesma cena em diferentes resoluções.

3.1.3 Sistemas para classificação de imagens

Existe uma grande variedade de sistemas para classificação de imagens. Sistemas proprietários com potencialidade de extrair informação com muita eficiência dos mais variados sensores remotos e ainda uma gama de *software* livres, alguns com eficiência de classificação muito próxima de sistemas proprietários. Na tabela 2 é apresentada uma lista com exemplos de alguns sistemas de Processamento Digital de Imagens – PDI, que realizam a classificação automática de imagens com algumas características relevantes.

Tabela 2 - Sistemas de processamento digital de imagens - PDI

<i>SOFTWARE</i> DE PDI	QUALIDADES	LIMITAÇÕES
SPRING	É livre; Elevado número ferramentas; Faz análise espacial.	Utiliza banco de dados próprio; <i>Interface</i> pouco intuitiva.
GRASS GIS	É livre; Faz análise espacial, incluindo edição de topologia.	<i>Interface</i> gráfica pouco amigável; Banco de dados próprio; Limitações no processamento.
OpenEv	É livre; Possui visualização em 3D; Georreferenciamento de imagens.	Não possui boa impressão de mapas; <i>Interface</i> pouco elaborada.
InterIMAGE	É livre; Análise OBIA; Inserção de outros operadores.	Banco de dados próprio; <i>Interface</i> pouco intuitiva; Limitações no processamento; Não faz avaliação da precisão do resultado.
MultiSpec	É livre; <i>Interface</i> intuitiva; Processamento hiperespectral; Não precisa de instalação.	Limitações no processamento.
gvSIG	É livre; Faz análise espacial, incluindo edição de topologia.	Limitações no processamento.

ArcMap	Faz análise espacial, incluindo edição de topologia; <i>Interface</i> intuitiva; Conexão do banco de dados; Conjunto de ferramentas abrangente.	É proprietário; Licença de alto custo.
Envi	Conjunto muito abrangente de ferramentas; <i>Interface</i> intuitiva; Processamento hiperespectral; Visualizador n-dimensional.	É proprietário; Licença de alto custo.
ERDAS	Sistemas especialistas e classificação de imagens <i>subpixel</i> ; Processamento hiperespectral; Compressão de imagens.	É proprietário; Não tem abordagem multiescala.
GEODMA	É livre; Ferramentas de mineração de dados;	Funcionamento acoplado ao sistema TerraView.
Definiens Developer	Análise OBIA; Extração de feições com qualidade; Faz avaliação da precisão do resultado.	É proprietário; Licença de alto custo; Não faz análise de componentes principais.
IDRISI Taiga	Classificadores de redes neurais; Abordagem multiescala.	É proprietário.
PCI Geomatics	Conjunto de ferramentas abrangente; <i>Interface</i> intuitiva. Mosaico automático inteligente.	É proprietário.
ERMMapper	Conexão direta com ArcGIS; Conexão do banco de dados; <i>Interface</i> intuitiva.	É proprietário.
ILWIS	É livre; Conexão do banco de dados; <i>Interface</i> intuitiva.	Limitações no processamento.

3.1.3.1 O sistema InterIMAGE

Dentre os *software* de classificação baseados em objetos, destaca-se o InterIMAGE, sistema de código aberto, desenvolvido pelo Laboratório de Visão Computacional do Departamento de Engenharia Elétrica da Pontifícia Universidade Católica do Rio de Janeiro e pelas divisões de Processamento de Imagens e de Sensoriamento Remoto do Instituto Nacional de Pesquisas Espaciais (COSTA *et al.*, 2008).

Como o InterIMAGE baseou-se no aplicativo GeoAIDA (BUCKNER *et al.*, 2001), ele herdou deste sistema o seu *design* funcional básico, estruturas de conhecimento e mecanismos de controle (COSTA *et al.*, 2009), deixando o sistema como suporte para integração de operadores de processamento de imagens no processo de interpretação. Tais operadores são tratados como programas externos pelo seu mecanismo de controle, podendo ser codificados por qualquer linguagem computacional e podem até mesmo ser programas proprietários (COSTA *et al.* 2008; COSTA *et al.* 2010).

Pahl (2003) descreve o funcionamento do *software* (figura 5) baseado no projeto GeoAIDA. No lado esquerdo da figura são mostradas as entradas do processo de interpretação. A rede semântica representa o modelo de conhecimento definido pelo especialista humano e processado pelo sistema para a interpretação de uma cena (extensão geográfica), recoberta por uma ou mais imagens ou dados vetoriais geo-referenciados. Durante a interpretação da cena, os dados de entrada são processados com o auxílio de operadores *top-down* e *bottom-up*. Operadores *top-down* são responsáveis por particionar (segmentar) a cena em sub-regiões (segmentos) e geram as hipóteses de objetos (atribuir classes aos segmentos). Operadores *bottom-up* avaliam as hipóteses de objetos, validando-as ou não, e resolvendo eventuais conflitos espaciais, reunindo os objetos em grandes unidades (grupos). No lado direito da figura é apresentado o resultado da interpretação, na forma de um mapa temático com nível de detalhamento dependente das especificações e escolhas do analista.

O modelo de conhecimento sobre a cena a ser interpretada está representado em uma rede semântica. Pahl (2003) define rede semântica com um grafo orientado, no qual os nós representam objetos, ideias, acontecimentos ou fatos ligados por arcos que descrevem a relação dos nós entre si, em que a associação dos nós é estritamente hierárquica, isto é, cada nó tem exatamente um nó superior (nó pai). Cada nó corresponde a uma classe de objeto potencialmente presente na cena. Podem-se associar atributos a cada nó. Além de atributos

genéricos como *Name* e *Class*, pode-se associar a cada nó um operador *top-down* e um operador *bottom-up*.

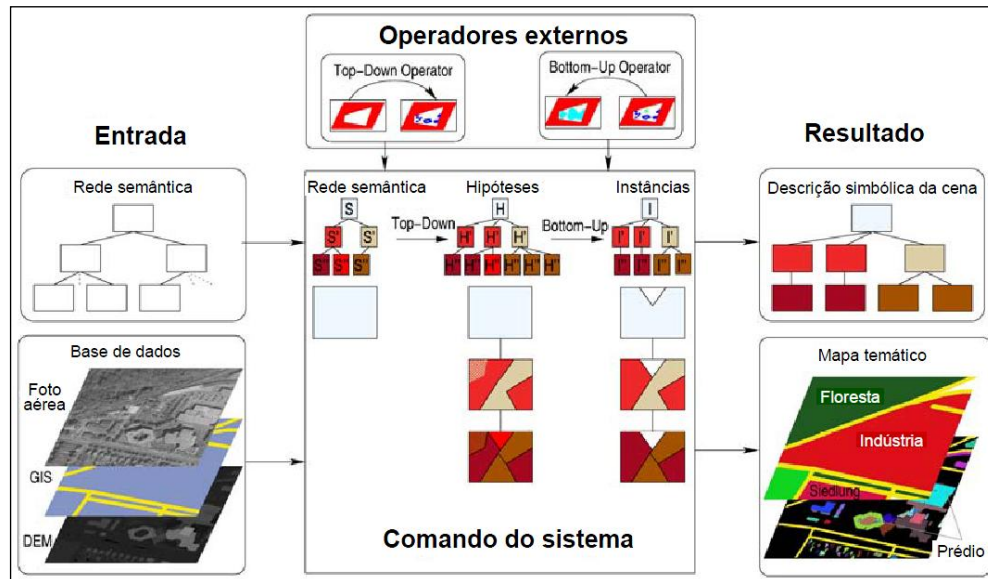


Figura 5 - Esquema do processo de interpretação de uma cena no InterIMAGE
Fonte: Adaptada de Pahl (2008).

3.2 Qualidade de dados

Segundo Monico *et al.* (2009), qualquer medida está sujeita aos mais variados tipos de erros, quer seja de natureza grosseira, sistemática ou aleatória. A confiabilidade de qualquer mapa está diretamente vinculada à sua exatidão, a qual indica a proximidade de uma observação ou medida de seu valor real. Nesse sentido, realizada a classificação de imagens, necessita-se de algum procedimento estatístico que defina a acurácia ou exatidão da mesma (BERNARDES *et al.*, 2006).

De acordo com Bicas (2003), precisão refere-se à invariabilidade com que são obtidos os valores de medidas realizadas em condições rigorosamente similares, esta medida muitas vezes é confundida com a exatidão, que se refere à variabilidade das medidas, sendo o valor médio da distribuição o “exato”. Outro termo que é utilizado para indicar a qualidade de uma grandeza é a acurácia, que é definida por Mikhail & Ackermann (1976) como sendo o grau de proximidade de uma estimativa com seu parâmetro.

Na figura 6 é apresentada uma ilustração diferenciando exatidão, precisão e acurácia, onde: no alvo “a” os resultados são acurados porque, em média, estão próximos do valor verdadeiro, mas não são precisos porque há certa dispersão; no alvo “b” os dados são precisos e acurados; no alvo “c”, a pior situação, os dados não são nem precisos nem acurados. No alvo

“*d*” os resultados são precisos porque estão próximos entre si, mas não são acurados porque estão distantes do valor verdadeiro.

Comparando o alvo “*d*” com a situação ideal “*b*”, pode-se dizer que os dados de “*d*” seguem um erro sistemático e que (se fossem tiros no alvo, concluía-se que o atirador é bom, porém a arma deveria estar desregulada). Já em no alvo “*a*” deduz-se que a mira da arma está em ordem, mas o atirador não tem habilidade suficiente.

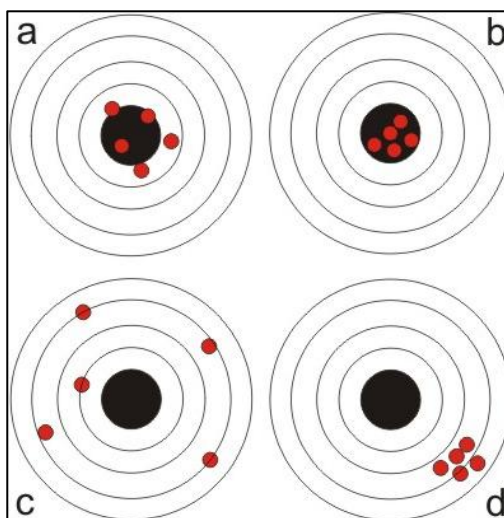


Figura 6 - Diferença de acurácia e precisão

De acordo com Montgomery & Schuch (1993), citado por Antunes (1997), em qualquer mapa temático obtido por meio da classificação digital, pode ser efetuada a análise da acurácia referente às seguintes componentes:

- posicional, que se refere à precisão espacial do mapa e que é variável de acordo com a sua escala; e
- temático, que se refere à precisão da classificação das diferentes categorias que compõem o mapa.

As componentes citadas são interdependentes, entretanto, a avaliação é geralmente realizada de forma independente, considerando se a precisão posicional verificada é compatível com a escala do levantamento e com a retificação da imagem (ANTUNES, 1997).

3.2.1 Matriz de confusão

Para avaliar o desempenho de uma classificação de forma objetiva é necessário utilizar critérios quantitativos. Dentre os métodos de avaliação da qualidade de classificações

discutidos na literatura, os mais utilizados são baseados na matriz de confusão ou matriz de erros.

Segundo Congalton & Green (1999), a matriz de confusão é uma maneira muito eficaz para representar a precisão do mapa. Uma matriz de confusão ou matriz de erros é uma matriz quadrada que expressa a relação do número de unidades de amostra atribuída a uma categoria particular de duas classificações. Nessa matriz, geralmente, as colunas representam os dados de referência (verdade de campo) e as linhas representam a classificação obtida com algum método de classificação automática.

Em uma matriz de confusão, a frequência observada na diagonal (n_{ii}) representa os elementos classificados corretamente. A coluna marginal (n_{i+}) representa o total de elementos classificados para uma categoria i . A linha marginal (n_{+i}) representa o total de elementos de referência amostrados para uma categoria i (tabela 3).

Congalton (1991) afirma que se a matriz for mal construída, toda a análise é insignificante. Portanto, os seguintes fatores devem ser considerados para a construção de uma matriz corretamente: padrão, unidade e número de amostras. Estes fatores fornecem informações essenciais para a avaliação de uma matriz.

Tabela 3 - Estrutura de uma matriz de confusão

		j = Colunas (Referência)			Total de Linhas
		1	2	k	n_{i+}
i = Linhas (Classificação)	1	n_{11}	n_{12}	n_{1k}	n_{1+}
	2	n_{21}	n_{22}	n_{2k}	n_{2+}
	k	n_{k1}	n_{k2}	n_{kk}	n_{k+}
	Total de Colunas	n_{+1}	n_{+2}	n_{+k}	n
		n_{+i}			

Fonte: Adaptada de Congalton & Green (1999).

3.2.2 Padrão, unidade e número de amostras

De acordo com Brites *et al.* (1996), entende-se por padrão de amostragem a maneira, em termos espaciais, em que as amostras serão tomadas sobre uma dada área. Em sensoriamento remoto, estes padrões são de fundamental importância, uma vez que, a depender deles, poder-se-á incorrer na incorporação de amostras com alta correlação espacial.

Dentre os padrões de amostragem têm-se: amostragem totalmente casualizada, onde todos os indivíduos possuem igual chance de serem selecionados; a amostragem sistemática, onde a amostragem é feita por um processo probabilístico não casualizado, seu critério de probabilidade se estabelece por meio da aleatorização da primeira unidade amostral. A amostragem sistemática estratificada, que combina propriedades da amostragem sistemática e da amostragem estratificada, propiciando a cobertura de toda a área de interesse e, simultaneamente, preservando a casualidade do procedimento (BRITES *et al.*, 1996).

Unidades de amostragem são as porções do mapa que serão selecionadas para avaliação da precisão. Existem quatro escolhas possíveis para a unidade de amostragem: (1) um único *pixel*, (2) um conjunto de *pixels* (muitas vezes um quadrado 3 x 3 *pixels*), (3) um polígono (ou objeto) e (4) um conjunto de polígonos (CONGALTON & GREEN, 1999).

De acordo com Torrijos Cadena (2011), normalmente duas estratégias podem ser usadas no sentido de calcular o número de amostras necessárias para computar a acurácia: a distribuição binomial e a multinomial. 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.

Congalton & Green (1999) afirmam que a criação de uma matriz de erros não é simplesmente uma questão de correto ou incorreto (o caso binomial), e sim uma questão de qual ou quais categorias de erros estão confusas. Portanto, o uso de uma distribuição binomial para a determinação do tamanho da amostra para uma matriz de confusão não é apropriado e sim uma distribuição multinomial, já que esta leva em consideração o número de classes. Com base nisso, os autores apresentam a equação 3.5 para determinação do número de amostras:

$$N = B\Pi_i(1 - \Pi_i)/b^2, \text{ onde:} \quad (3.5)$$

N = número de amostras;

B = obtido de uma tabela de distribuição qui-quadrado com um grau de liberdade e $1 - \alpha / k$;

k = número de classes;

$1 - \alpha$ = grau de confiança;

Π_i = proporção da classe com maior área no mapa; e

b = máximo erro admissível.

3.2.3 Coeficientes de concordância

Seguindo os critérios para a construção da matriz de confusão, a avaliação da acurácia pode ser obtida por meio de coeficientes de concordância derivados dela, sendo que estes podem ser expressos como concordância total ou para classes individuais (FIGUEIREDO & VIEIRA, 2007).

O coeficiente de concordância total mais utilizado, segundo Levada (2010), é a taxa de acerto ou Exatidão Global (HELLDEN *et al.*, 1980). Porém, apenas o cálculo da exatidão global não é suficiente, havendo a necessidade de índices que levem em conta a matriz por completo como, por exemplo, os Coeficientes de Concordância *Tau* (KLECKA, 1980) e *Kappa* (COHEN, 1960).

Os coeficientes de concordância por classe irão avaliar as classes de forma individual. Dentre os métodos mais utilizados na literatura, tem destaque o *Kappa* condicional (BISHOP *et al.*, 1975). A exatidão do usuário e do produtor foi introduzida em estudos de sensoriamento remoto realizados por Story & Congalton (1986).

De acordo com Antunes (1997), a avaliação da acurácia por meio de diferentes tipos de coeficientes de concordância permite a obtenção de um grau de confiabilidade das categorias classificadas na imagem, sob diferentes perspectivas e metodologias.

3.2.3.1 Exatidão Global

A taxa de acerto ou Exatidão Global (P_o), proposta por Hellden *et al.* (1980) (Equação 3.6), é calculada dividindo-se a soma dos valores da diagonal principal, que representa o

número de amostras classificadas corretamente n_{ii} , pelo número total de amostras coletadas N , ou seja:

$$P_o = \frac{\sum_{i=1}^M n_{ii}}{N}, \text{ onde:} \quad (3.6)$$

M = número de categorias informacionais presentes na matriz de erros;

n_{ii} = elementos da diagonal principal, ou seja, elementos classificados corretamente; e

N = número total de amostras.

Segundo Brites *et al.* (1996), o índice G apresenta os maiores valores quando comparado a outros índices pelo fato de considerar apenas a diagonal principal da matriz de erros, ignorando a ocorrência de concordância casual entre as classes.

3.2.3.2 Coeficiente Kappa

Cohen (1960) define *Kappa* (K) como um coeficiente de concordância entre dados da classificação e verdade de campo para escalas nominais.

Desta forma, K , assim como G, também representa a concordância entre a classificação e a realidade de campo. Ele determina a concordância esperada *a posteriori*, ou seja, a concordância esperada somente poderá ser determinada após a construção da matriz de confusão (BERNARDES *et al.*, 2006).

O coeficiente de concordância K pode ser determinado pela equação 3.7.

$$K = \frac{P_o - P_c}{1 - P_c}, \text{ onde:} \quad (3.7)$$

P_o = exatidão global (proporção de unidades que concordam); e

P_c = proporção de unidades que concordam por casualidade, representada pela equação 3.8.

$$P_c = \frac{\sum_{i=1}^M n_{i+} n_{+i}}{N^2}, \text{ onde:} \quad (3.8)$$

M = número de classes;

n_{i+} = total de elementos classificados para uma categoria i ;

n_{+i} = total de elementos de referência amostrados para uma categoria i ; e
 N = número total de amostras.

O resultado da estatística *Kappa* normalmente é comparado aos valores contidos na tabela 4, proposta por Landis & Koch (1977), a fim de indicar a qualidade do mapa temático. Embora essa tabela tenha sido desenvolvida para analisar resultados de diagnósticos clínicos, a mesma tem sido referência para classificar mapas resultantes da utilização de imagens de sensoriamento remoto (PRADO, 2009).

Tabela 4 - Qualidade da classificação associada ao índice *Kappa*

Índice <i>Kappa</i>	Desempenho
< 0	Péssimo
$0 < k \leq 0,2$	Ruim
$0,2 < k \leq 0,4$	Razoável
$0,4 < k \leq 0,6$	Bom
$0,6 < k \leq 0,8$	Muito Bom
$0,8 < k \leq 1,0$	Excelente

Fonte: Adaptada de Landis e Koch (1977).

Segundo Brites *et al.* (1996), o índice *Kappa* é recomendado como uma medida apropriada para avaliar a exatidão porque não representa apenas os valores que se situam na diagonal principal da matriz, mas ela por inteiro, sendo esta uma forma padronizada para reportar erros em locais específicos.

3.2.3.3 Coeficiente *Tau*

O coeficientes de concordância *Tau* (T) (Klecka, 1980), ao contrário do coeficiente *Kappa*, baseia-se na probabilidade *a priori*, permitindo, assim, a obtenção do valor da concordância esperada (P_e) mesmo antes de efetuar a checagem dos resultados da simulação de mapeamento. Isso fornece uma clara indicação de como a classificação se comporta quando comparada com a atribuição casual dos *pixels* às categorias ou classes (BERNARDES *et al.*, 2006).

O coeficiente de concordância *Tau* pode ser determinado pela equação 3.9.

$$T = \frac{P_o - P_r}{1 - P_r}, \text{ onde:} \quad (3.9)$$

T = coeficiente *Tau*;

P_o = exatidão global (proporção de unidades que concordam);

$P_r = 1/M$; e

M = número de classes.

Segundo Brites *et al.* (1996), *Tau* é um ajuste do percentual de concordância (G) pelo número de categorias. À medida que este número aumenta, *Tau* se aproxima da percentagem de G.

A interpretação do coeficiente *Tau* é ligeiramente diferente do *Kappa*: ele indica a percentagem de elementos (*pixels*) a mais que foi classificada corretamente em relação ao que seria esperado apenas pela sorte (LEVADA, 2010).

Antunes (2003) afirma que, similarmente como o coeficiente *Kappa*, o coeficiente *Tau* mede o grau de concordância em escalas nominais, assumindo que: as unidades são independentes; as classes ou categorias da escala nominal são independentes e mutuamente exclusivas; o classificador e os pontos de referência operam de forma independente.

3.2.3.4 *Kappa* Condicional

Rosenfield & Fitzpatrick-Lins (1986) propõem o *Kappa* condicional (K_i) como uma medida de precisão para categoria individual, baseado no índice K de Cohen (1960). Sendo calculado pela equação 3.10.

$$K_i = \frac{\sum_{i-1}^M n_{i+} n_{+i}}{N^2}, \text{ onde:} \quad (3.10)$$

K_i = *Kappa* condicional;

N = número total de amostras;

n_{i+} = total de elementos classificados para uma categoria i ;

n_{+i} = total de elementos de referência amostrados para uma categoria i ; e

M = número de classes.

3.2.3.5 Exatidão do usuário e do produtor

A partir dos erros de omissão (ϵ_o) (amostras de uma classe específica que foram classificadas como outras) e de comissão (ϵ_c) (amostras de outras classes classificadas como uma classe específica) são calculadas as exatidões do produtor (e_p) e do usuário (e_u).

A “ e_p ” é calculada a partir dos dados da referência (verdade), dividindo o número total de amostras corretamente classificadas em uma categoria pelo número de amostras que foram classificadas nessa categoria, ou seja, o total da coluna (STORY & CONGALTON 1986). É calculada pela equação 3.11.

$$e_p = \frac{n_{ii}}{n_{+i}}, \text{ onde:} \quad (3.11)$$

e_p = exatidão do produtor;

n_{ii} = elementos da diagonal, ou seja, elementos classificados corretamente; e

n_{+i} = total de elementos de referência amostrados para uma categoria i .

Já a exatidão do usuário “ e_u ” é calculada a partir dos dados da classificação, dividindo o número total de amostras corretamente classificadas em uma categoria pelo número de amostras que foram classificadas nessa categoria, ou seja, o total da linha (STORY & CONGALTON 1986). É calculada pela equação 3.12.

$$e_u = \frac{n_{ii}}{n_{i+}}, \text{ onde:} \quad (3.12)$$

e_u = exatidão do usuário;

n_{ii} = elementos da diagonal, ou seja, elementos classificados corretamente; e

n_{i+} = total de elementos classificados para uma categoria i .

4 MATERIAL E MÉTODOS

4.1 Área de estudo

A área selecionada para este estudo foi a cidade satélite de Sobradinho - DF, região administrativa RA V, e parte da cidade satélite de Sobradinho II - DF, RA XXVI, (Figura 7).

A RA V corresponde a cidade satélite de Sobradinho, que foi fundada em 13 de maio de 1960 para abrigar a população que vivia nos acampamentos de empreiteiras localizadas na Vila Amauri, no Bananal e nas invasões próximas à Vila Planalto, inundadas pelas águas do Lago Paranoá, e também aos funcionários da NOVACAP e do Banco do Brasil que vieram para a implantação da nova capital. Em 1964, por meio da Lei nº 4.545, de 10 de dezembro de 1964, Sobradinho tornou-se a RA V e o Decreto nº 11.921 fixou os limites da região (CODEPLAN, 2011).

No início dos anos 1990 foi criado o Núcleo Habitacional Sobradinho II como parte do Programa de Assentamento de População de Baixa Renda. O objetivo desse programa foi beneficiar famílias que compartilhavam um lote com outras famílias e também fixar os moradores das invasões do Ribeirão Sobradinho. Em 27 de janeiro de 2004, com a Lei nº 3.314, Sobradinho II foi separada de Sobradinho e transformada na RA XXVI (CODEPLAN, 2011).

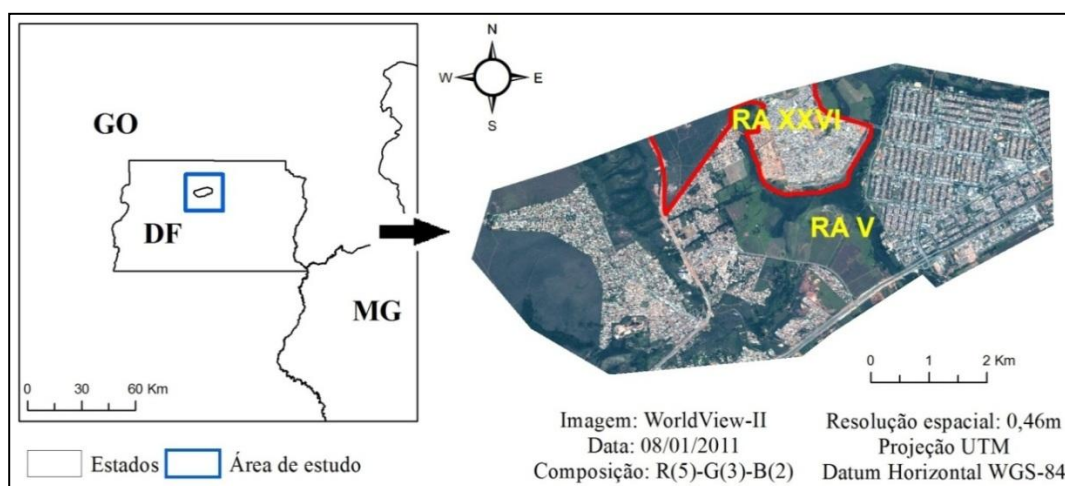


Figura 7 - Localização da área de estudo e abrangência das regiões administrativas V e XXVI

4.1.1 Áreas-teste

A área de estudo está dividida em três áreas-teste (Figura 8). Cada área-teste possui a dimensão de 700 x 400 metros, ou seja, 280.000 m². Estas dimensões foram definidas levando

em consideração limitações do InterIMAGE em termos de processamento de imagens de grandes dimensões e a busca por uma maior variedade de alvos urbanos.

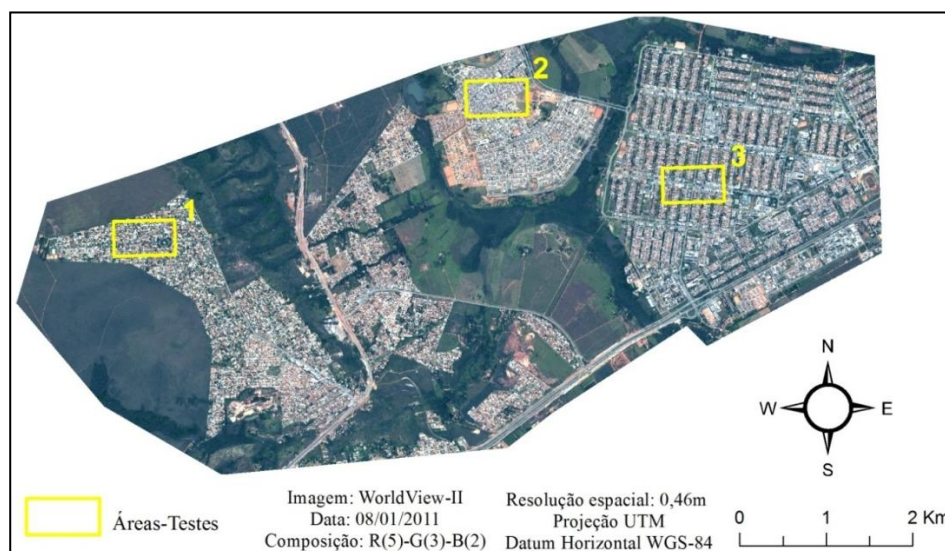


Figura 8 - Localização das áreas-teste

A área-teste 1 (Figura 9) é parte do condomínio Vivendas Bela Vista, Grande Colorado, em Sobradinho (RA V). Esta área foi escolhida por representar bem as áreas com moradias de classe média alta, existentes na RA V. Estas áreas caracterizam-se por apresentar grandes casas residenciais, com coberturas entre 350 a 500 m². Outra característica que diferencia essa área das demais é a presença de grandes áreas verdes (árvores e gramíneas), piscinas e telhados, com uma característica peculiar, que é o uso de cobertura de cimento com pigmentação verde.



Figura 9 - Localização de área-teste 1

A área-teste 2 (Figura 10) faz parte do Setor Oeste da cidade satélite de Sobradinho II (RA XXVI).




Figura 10 - Localização de área-teste 2

Assim como a área-teste 1, a área-teste 2 foi escolhida pela sua riqueza de alvos urbanos. Diferente das outras áreas, ela apresenta uma grande quantidade de pequenas casas residenciais (área construída variando de 50 a 100 m²), separadas, geralmente, por um muro, dificilmente com presença de jardins e quintais, fazendo com que as casas fiquem muito próximas umas das outras, dando a sensação de continuidade (casas geminadas) quando utilizam um mesmo tipo de cobertura.

Um diferencial desta área-teste, que contribuiu para sua escolha, consiste em uma grande concentração de alvos específicos, como, por exemplo, coberturas com telhas de amianto e solo exposto. Estes alvos são importantes, pois são comuns em áreas urbanas e suas identificações em classificações geralmente estão sujeitas a grande mistura com outros alvos.

A área-teste 3 (Figura 11) compreende parte das quadras 3, 4, 5 e 6, inseridas na RA V. Esta área foi escolhida por apresentar, além de características como casas próximas com cobertura de mesmo material, casas mais afastadas com jardins, quintais, piscinas e telhados com materiais diversos, apresentando edificações com áreas construídas variando de 500 a 800 m² (as medidas de área foram feitas com a ferramenta *Measure an area*, no software ArcGIS 9.3) em locais que apresentam características diferenciadas das áreas residenciais, podendo ser

entendidas como comerciais (cerca de 500 a 800 m²) de metal, além de grandes estacionamentos de asfalto. Existe também a presença de locais destinados a jardins e áreas verdes dentro das quadras.



Figura 11- Localização de área-teste 3

4.2 Materiais utilizados

Para execução deste trabalho foram utilizados os seguintes produtos:

- a) Duas imagens do sensor Worldview II: uma pancromática com resolução espacial de 0,46 m e outra multiespectral, com oito bandas espectrais com resolução espacial de 1,84 m e resolução radiométrica de 11 bits, tomadas em 08/11/2011;
- b) Arquivos vetoriais no formato ESRI Shapefile com polígonos das quadras e arruamentos das áreas de estudo, elaborados pela TERRACAP - Agência de Desenvolvimento do Distrito Federal.

Para a realização das classificações das imagens e demais procedimentos foram utilizados os seguintes pacotes de *software*:

- a) ArcGIS v9.3 (ESRI, 2008);
- b) ENVI v4.7 (ITT, 2009);
- c) SPRING v5.2 (INPE, 1996); e
- d) InterIMAGE v1.27 (COSTA *et al.* 2008; COSTA *et al.* 2010).

4.3 Métodos

A figura 12 mostra esquematicamente as etapas metodológicas do trabalho.

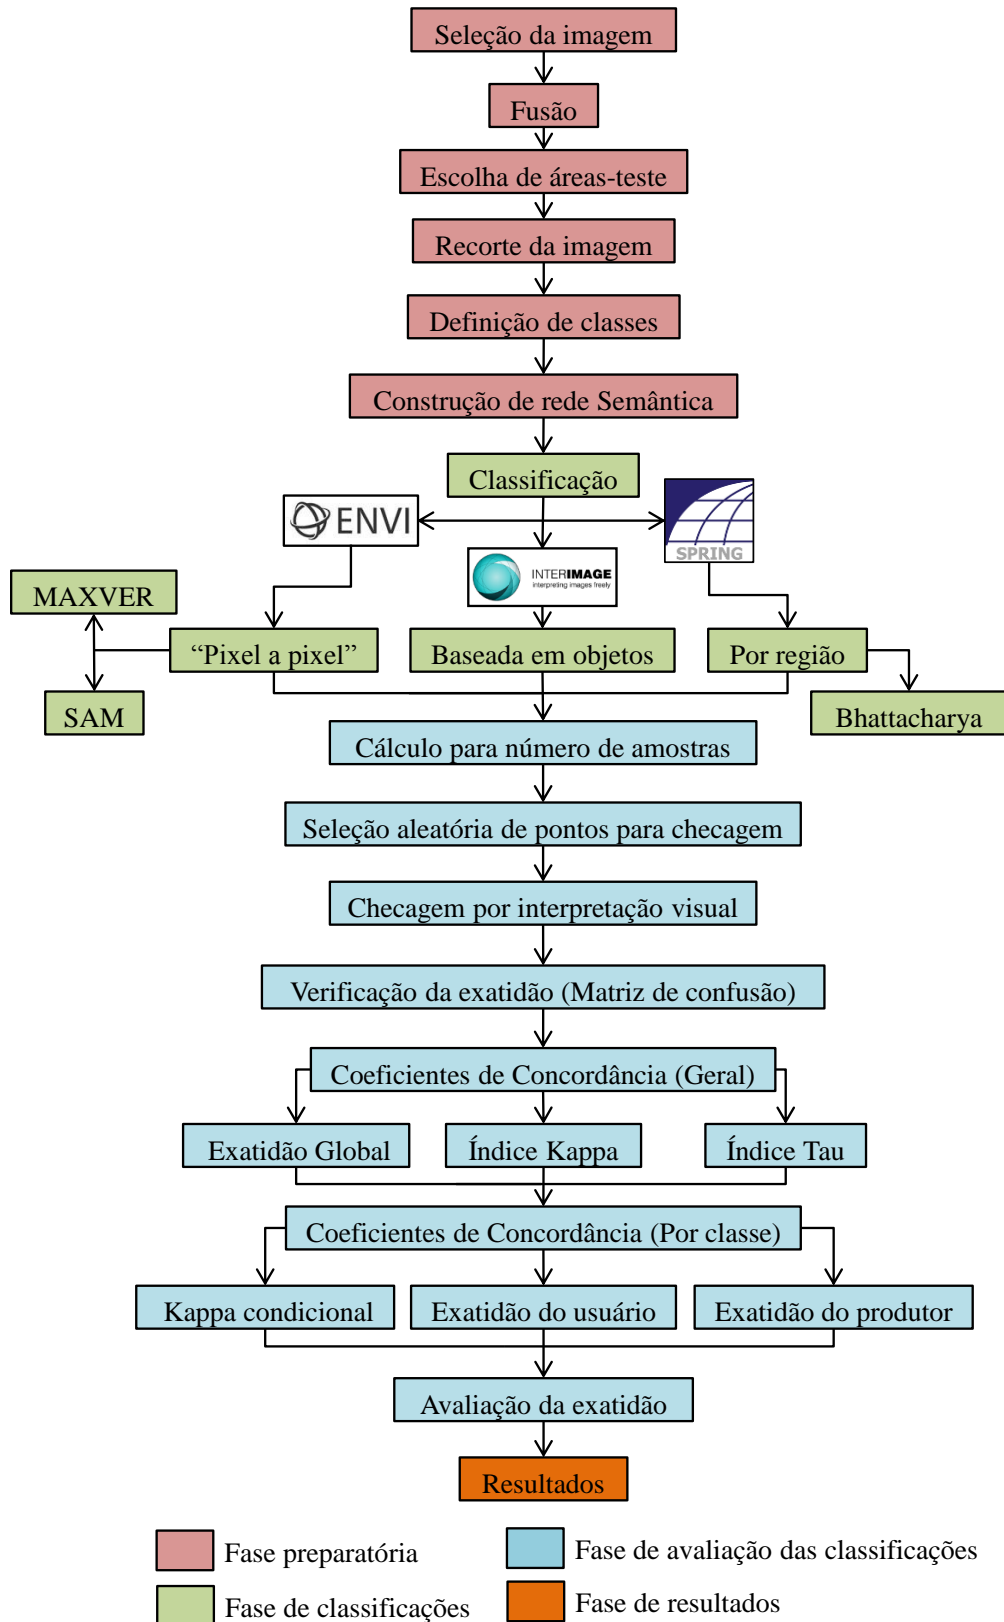





Figura 12 - Esquema das etapas metodológicas do trabalho





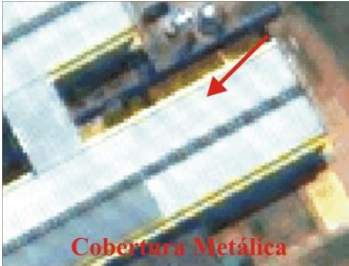
Os métodos do trabalho foram divididos em quatro fases: a) fase preparatória, onde foram realizados todos os trabalhos que precedem à classificação e análise de qualidade; b) fase de conhecimento, na qual foram realizadas todas as classificações, além de seleção e checagem de pontos; c) fase de análise de resultados, onde foi avaliada a qualidade de cada classificação; e d) fase de resultados, onde os dados de qualidade foram sistematizados para possibilitar a análise.






4.3.1 Fase preparatória

Como as imagens do Worldview II já foram fornecidas georreferenciadas no Datum WGS-84, pela Digital Globe, o primeiro passo foi submetê-las a um processo fusão de imagens, onde foi utilizado o método *pan-sharpening* recomendado por Carvalho *et al.* (2011), em que as bandas multiespectrais foram fusionadas com a banda pancromática. Logo em seguida, foi feito um recorte utilizando, como máscara, os vetores das áreas-teste selecionadas, e, posteriormente, foram individualizadas classes para cada área-teste, conforme o quadro 1.

Quadro 1 - Classes identificadas na imagem Worldview II

Classe (imagem)	Definição	Ocorrência
	A classe Asfalto refere-se a revestimentos asfálticos, geralmente de cor escura, composto por material cimentante, betume, alcatrão, dentre outros metais.	Ruas e estacionamentos fora das quadras residenciais de todas as áreas.
	A classe Cobertura de Cerâmica Clara refere-se a telhas de cerâmica com um tempo menor de cozimento, feitas com argila com baixo teor de óxido de ferro, apresentando coloração clara.	Dentro das quadras residenciais das áreas 1 e 3.
	A classe Cobertura de Cerâmica refere-se a telhas de cerâmica com um tempo maior de cozimento, feitas com argilas com alto teor de óxido de ferro, apresentando coloração avermelhada.	Dentro das quadras residenciais de todas as áreas.

 <p>Cobertura de Cimento Escuro</p>	<p>A classe Cobertura de Cimento Escuro refere-se a telhas de cimento compostas por fibra mineral extraída do amianto, que depois de um tempo de uso ficam com a coloração escura.</p>	<p>Dentro das quadras residenciais das áreas 2 e 3.</p>
 <p>Cobertura de Cimento Claro</p>	<p>A classe Cobertura de Cimento Claro refere-se a telhas de concreto (areia e cimento e materiais impermeabilizantes), além de uma pigmentação de cor branca na massa do concreto, resultando em uma coloração clara.</p>	<p>Dentro das quadras de todas as áreas.</p>
 <p>Cobertura de Cimento Médio</p>	<p>A classe Cobertura de Cimento Médio refere-se a telhas de amianto novas e telhas feitas de concreto (areia e cimento e materiais impermeabilizantes) com coloração cinza claro.</p>	<p>Dentro das quadras de todas as áreas.</p>
 <p>Telha de Cimento Verde</p>	<p>A classe Cobertura de Cimento Verde refere-se a telhas de concreto (areia e cimento e materiais impermeabilizantes), além de uma pigmentação de cor verde na massa do concreto, resultando em uma coloração esverdeada.</p>	<p>Dentro das quadras da área 1.</p>
 <p>Cobertura Metálica</p>	<p>A classe Cobertura Metálica refere-se a telhados de metal, em geral que tenham como matéria-prima o aço revestido por zinco.</p>	<p>Dentro das quadras das áreas 2 e 3 (galpões, fábricas e quadras</p>

		cobertas).
	A classe Piscina consiste em piscinas, ou seja, tanques de água para esporte e lazer.	Dentro das quadras das áreas 1 e 3.
	A classe Solo Exposto consiste em áreas em que o solo está completamente à mostra. Sua coloração varia de amarelo claro a laranja.	Ruas não pavimentadas, campos de futebol e áreas desocupadas. Está presente em todas as áreas.
	A classe Sombra consiste em áreas da imagem com pouca iluminação, causada pelo fato da imagem não ter sido tomada com o sensor e sol ao nadir. Quanto maior a altura do alvo maior é a sombra projetada.	Sempre ao lado de edificações e grandes árvores. Presente em todas as áreas.
	A classe Vegetação Arbórea é composta por árvores e arbustos maiores, geralmente com coloração verde-escuro e pode apresentar-se em aglomerações ou árvores isoladas.	Jardins, canteiros centrais e parques. Presente em todas as áreas.
	A classe Vegetação Rasteira é composta por gramíneas e pequenos arbustos, tem coloração verde-claro.	Jardins, canteiros centrais e parques. Presente em todas as áreas.

Essa separação prévia das classes auxiliou a coleta de amostras de treinamento para as classificações por *pixel* e por região, e também para estruturação das redes semânticas de cada área-teste, pois, uma vez que se conhece a organização e a hierarquia das classes, torna-se possível a estruturação das mesmas em uma rede semântica que irá subdividir o processo de interpretação da imagem, tornando a classificação mais simples.

4.3.2 Fase de classificações

Nesta fase foram realizadas as classificações utilizando-se os seguintes classificadores: *pixel a pixel* (Maxver e SAM) por região (Bhattacharyya) e a classificação com orientação a objetos. Nesta fase também foram realizadas seleções e checagem de pontos para validação do estudo.

A classificação Maxver consistiu na coleta de amostras de treinamento sobre a imagem fusionada, onde, por interpretação visual, foram identificados e marcados os alvos de interesse (neste caso, as classes selecionadas foram as que compuseram a rede semântica de cada área-teste), em seguida foi realizada a classificação resultando na imagem classificada. A figura 13 apresenta um exemplo de coleta de amostras de treinamento para a área-teste 1.



Figura 13 - Amostras de treinamento coletadas sobre a imagem fusionada da área-teste 1 (classificação Maxver)

A classificação SAM foi realizada no *software* Envi, onde inicia-se pelo procedimento de redução da dimensão espectral, pela metodologia *Minimum Noise Fraction* (MNF) (GREEN

et al., 1988). Esse método, além de possibilitar a eliminação dos ruídos, permite também diminuir a dimensionalidade da imagem em eixos descritos pelos materiais ou feições físicas ambientais que constituem a cena, resultando em um novo conjunto de bandas que é ordenado segundo os autovalores de variância das mesmas.

O próximo passo foi a redução da dimensão espacial, onde foi utilizado o Índice de Pureza do *Pixel* (PPI) (BOARDMAN, 1995; KRUSE, 2003) que registra e contabiliza os *pixels*, que são vértices nas diferentes projeções do *simplex*. Consiste em um método que objetiva identificar os vértices de um conjunto convexo que definam uma melhor solução para problemas de programação linear. (CARVALHO JUNIOR *et al.*, 2003).

Desta forma, os pontos relativamente mais puros tendem a se repetir nas diferentes projeções, aumentando o seu valor PPI. O número de iterações é definido pelo usuário, quanto maior for o número de iterações estipuladas, mais fidedigna é a informação obtida. (CARVALHO JUNIOR *et al.*, 2003).

Buscando um maior refinamento, o processamento do PPI foi realizado com 10.000 (dez mil) iterações, visto que este valor representa o número de vezes que a reta que define a pureza do *pixel* foi disposta para coletar os *pixels* da extremidade e determinar o nível de pureza do mesmo.

Em seguida, foi realizada a identificação dos membros finais pelo visualizador n-dimensional, que gerou uma nuvem de pontos referentes aos *pixels* puros da etapa anterior em um espaço de atributos com n dimensões (“ n ” representa o número de bandas da imagem). Esse módulo permite a manipulação da nuvem de pontos de forma que se obtenha um posicionamento que melhor discrimine os diferentes grupos de espectros (Figura 14). (BOARDMAN & KRUSE, 1994).




Figura 14 - Visualização dos *pixels* puros em espaço n-dimensional para a área-teste 1

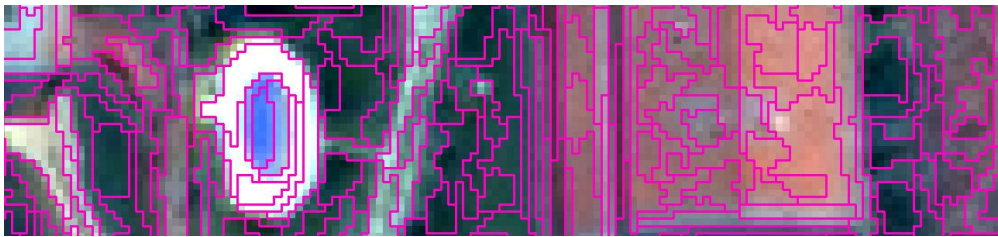
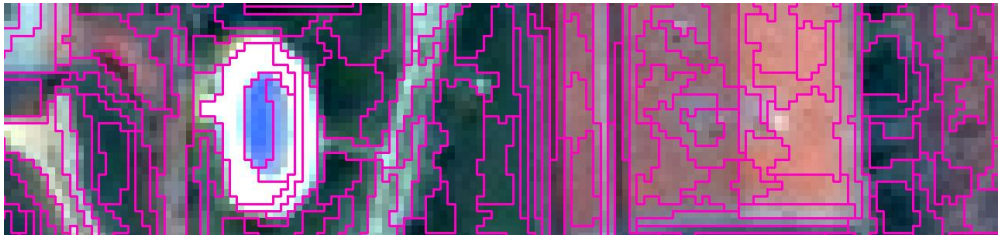
De posse dos membros finais (*endmembers*) extraídos do visualizador n-dimensional, aplicou-se o classificador SAM nos recortes das imagens das áreas-teste.

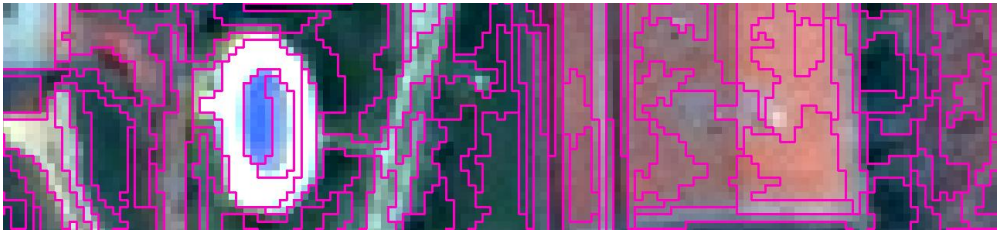
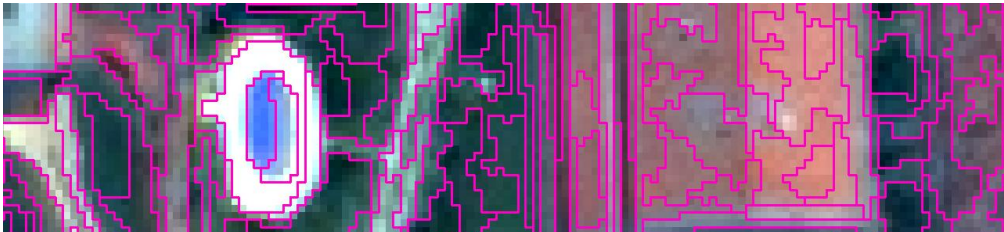
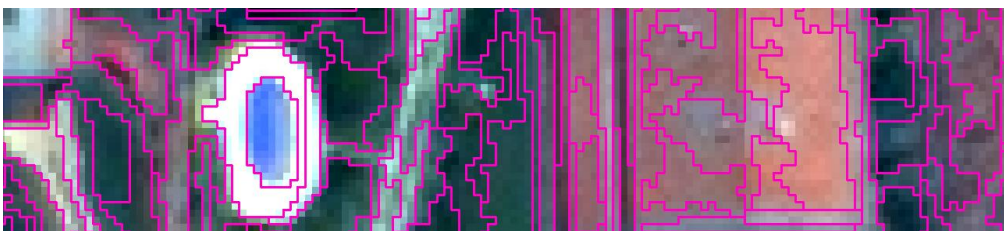
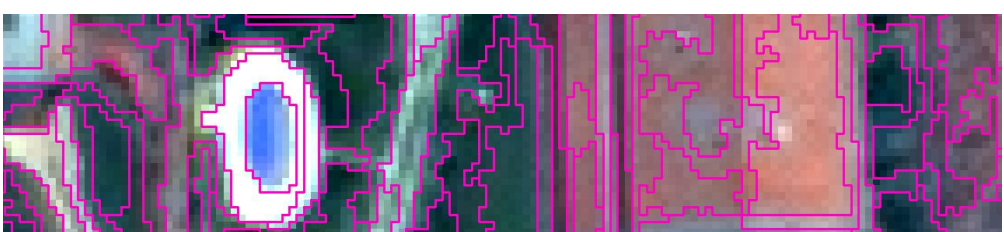
Diferentemente das classificações anteriores, a classificação por região foi desenvolvida no *software* SPRING v5.2 (INPE, 1996), seguindo as seguintes etapas: segmentação, extração de regiões e classificação com o algoritmo Bhattacharyya. Após a realização destas etapas tem-se como resultado um mapa temático.

A segmentação no SPRING foi feita utilizando um algoritmo por crescimento de regiões, desenvolvido pelo INPE (BINS *et al.*, 1996), que depende da definição de dois limiares, do grau de similaridade (agregação de *pixels* em função da semelhança do nível de cinza dos vizinhos) e da área (tamanho mínimo para o estabelecimento de uma região).

Para Coutinho (1997), os valores ideais de área e similaridade dependem principalmente dos padrões de repartição espacial dos objetos de cada área e da definição da generalização cartográfica ideal, em função da escala cartográfica da abordagem realizada. Não existe, portanto, uma padronização de valores destas variáveis para a obtenção de bons resultados, havendo a necessidade de vários testes entre várias combinações até o momento em que o resultado encontrado para a segmentação seja satisfatório. Assim, estas combinações encontradas podem não responder de maneira semelhante se forem aplicadas em outras áreas, mesmo que sejam imagens do mesmo sensor. No quadro 2 são apresentados exemplos de combinações de similaridade e área para a área-teste 1.

Quadro 2 - Combinações de similaridade e área para área-teste 1







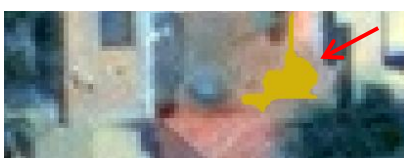


Similaridade	Área	Resultado
10	15	
15	20	

20	25	
25	25	
25	30	
30	35	

Com as amostras de treinamento coletadas (Quadro 3), foi executada a classificação com o algoritmo Bhattacharyya, que as utilizou para treinar o classificador, calculando a média e a matriz de covariância de cada classe. Em seguida, cada segmento foi alocado a uma dessas classes, segundo a menor distância de Bhattacharyya

Quadro 3 - Exemplos de amostras de treinamento para classificação por região Bhattacharyya para área-teste 1

Asfalto	
---------	--

Cobertura de Cerâmica Clara	
Cobertura de Cerâmica	
Cobertura de Cimento Claro	
Cobertura de Cimento Médio	
Cobertura de Cimento Verde	
Piscina	
Solo Exposto	
Sombra	
Vegetação Arbórea	



A fase final desse processo foi o mapeamento das classes em um modelo temático, no qual se associou cada um dos polígonos de treinamento a uma determinada classe de cobertura do solo identificada na imagem.

As classificações baseadas em objetos foram feitas no *software* InterIMAGE v1.27, iniciando com a estruturação das redes semânticas para cada área-teste (Figura 15). As classes que compuseram as redes semânticas foram as mesmas definidas na fase preparatória.

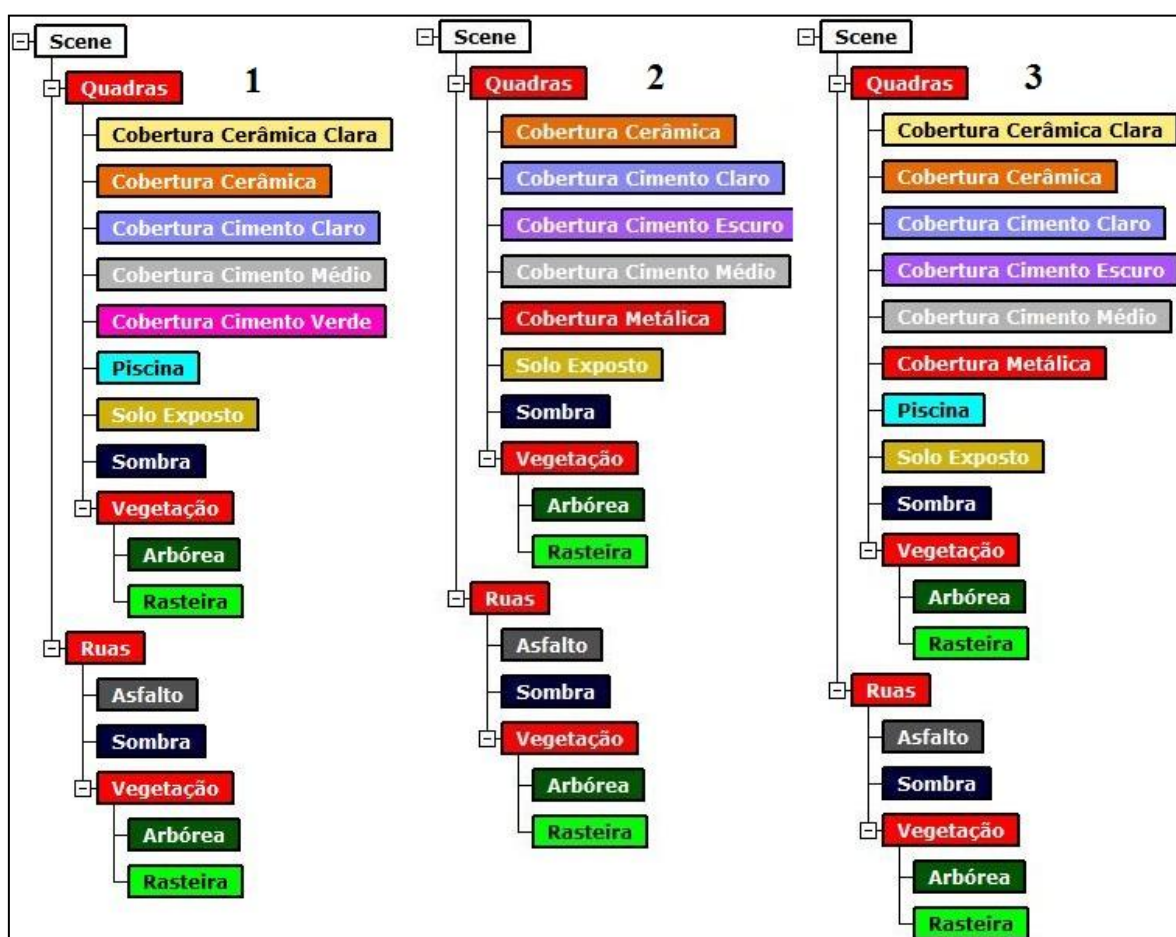


Figura 15 - Estruturação de redes semânticas para as três áreas-teste

Com as redes semânticas construídas, foram atribuídos operadores *top-down* a cada nó pai das redes, com o objetivo de passar para os seus nós filhos as máscaras, ou seja, as regiões geográficas. Para as três áreas-teste, os nós “Ruas” receberam operador holístico Top-Down

TA_Shape_FileImport, que possibilitou a restrição da atuação dos filhos apenas à abrangência do arquivo *shapefile* de arruamentos. Os nós “Quadras” receberam o operador holístico Dummy Top-Down, que apenas passou para os seus nós filhos a região geográfica de seu nó pai, no caso o nó *Scene*. Como foram atribuídos valores de pertinência para os nós “Ruas” maiores que para os nós “Quadras”, a área de abrangência dos nós “Quadras” ficou restrita às áreas geográficas que sobraram dos nós “Ruas”.

Ainda utilizando os operadores *top-down*, foram realizadas segmentações específicas para um dos nós filho, implementando o algoritmo desenvolvido por Baatz & Schäpe (2000). Todos os segmentos gerados sobre a imagem transformaram-se em hipóteses de objetos de cada nó filho, ou seja, cada classe.

Na sequência foram criadas e inseridas regras de decisão em cada nó da rede semântica, definidas a partir da análise dos valores espectrais nas diferentes bandas da imagem Worldview II (fusional) e das características específicas de cada alvo. Esta etapa foi realizada por meio das respostas encontradas no recurso *Analysis Manager* do *software* InterIMAGE, que permitiu o refinamento dos resultados por meio da análise de gráficos de histogramas.

4.3.3 Fase de avaliação das classificações

Para todas as classificações foram efetuadas as análises da acurácia temática. Para realização destas avaliações, foram seguidos os seguintes passos: cálculo para número de amostras; seleção aleatória de pontos para checagem; checagem por interpretação visual; verificação da exatidão (matriz de confusão) e cálculos de coeficientes de concordância de forma geral e por classe.

Para este trabalho, a unidade de amostragem escolhida foi o *pixel*, pelo fato de apresentar, dentre os classificadores avaliados, dois que utilizam apenas a informação espectral do *pixel* para encontrar sua classe mais provável.

Utilizando o *pixel* como unidade amostral, foi calculado o número de amostras por meio de uma distribuição multinomial (CONGALTON & GREEN, 1999), que leva em consideração o número de classes e a proporção da classe com maior área na classificação. Assim, para cada método utilizado, em cada área-teste, obteve-se um número ideal de amostras.

A equação 4.1 apresenta um exemplo do cálculo de amostragem para a classificação baseada em objetos da área-teste 1, onde N representa o número de amostras, B é obtido de

uma tabela de distribuição qui-quadrado com um grau de liberdade de $1 - \alpha / k$, onde k representa número de classes, que neste caso são onze ($k=11$). O nível de confiança desejado é de 95%, assim, tem-se 5% de erro admissível ($\alpha = 0,05$). Desta forma, $B(x_{(1.0,995454)}^2) = 8,051956$, Π_i representa a proporção da classe com maior área na classificação, neste caso é de 30,5% ($\Pi_i = 0,305$), b é o máximo erro admissível quanto ao número apropriado de amostras, neste caso 5% ($b = 0,05$). Assim, para esta área-teste, o tamanho da amostra seria:

$$N = B\Pi_i(1 - \Pi_i)/b^2 \quad (4.1)$$

$$N = 8,051956(0,305)(1 - 0,305)/(0,05)^2$$

$$N = 1,70681/0,0025$$

$$N = 682$$

A tabela 5 apresenta uma relação dos resultados dos cálculos para tamanho de amostra, para cada classificador aplicado em cada área-teste.

Tabela 5 - Tamanho das amostras para cada classificação

	OBJ	REG	MAX	SAM
Área-teste 1	682	528	460	637
Área-teste 2	581	669	589	636
Área-teste 3	478	633	463	548

Legenda: **OBJ**: classificação baseada em objetos, **REG**: classificação por região (Bhattacharyya), **MAX**: classificação por *pixel* (Maxver) e **SAM**: classificação por *pixel* (*Spectral Angle Mapper*).

Desta forma, foram escolhidos os maiores valores de amostras para cada área-teste a fim de garantir que as quatro classificações de cada área-teste ficassem bem representadas. Os valores em cinza na tabela representam os maiores valores que foram utilizados para representar cada área-teste. Foram coletados 20 amostras a mais para cada área teste a fim de alcançar o valor desejado, mesmo descartando algumas amostras que eventualmente caíssem nos limites das classes.

Conhecendo o tamanho da amostra para cada área-teste, realizou-se uma amostragem aleatória simples (por meio da ferramenta *Hawths Analysis Tools* no *software* ArcGIS v9.3), utilizando como espaço amostral um arquivo de pontos do centroide de cada *pixel* das imagens para cada uma das áreas-teste (Figura 16 a 18). Em seguida, foram atribuídas às amostras suas respectivas classes, este procedimento foi feito por interpretação visual na tela do computador, utilizando a imagem como fundo.

Os pontos de amostragem, rigorosamente checados e classificados, foram utilizados como dados de referência (verdade de campo), para compor a matriz de confusão. A matriz de confusão possibilitou calcular os índices de exatidão de concordância total (Exatidão Global e Coeficientes de Concordância de *Kappa* e *Tau*) e coeficientes de concordância por classe (*Kappa* condicional Exatidão do Usuário e do Produtor).




Figura 16 - Amostragem aleatória simples de pontos para área-teste 1

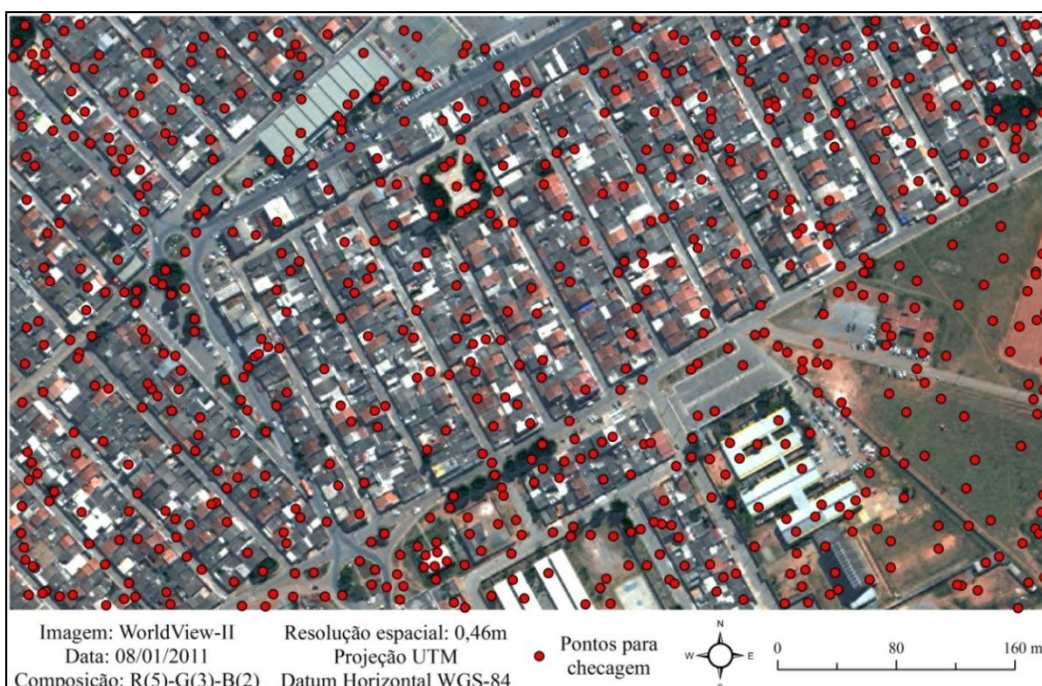


Figura 17 - Amostragem aleatória simples de pontos para área-teste 2



Figura 18 - Amostragem aleatória simples de pontos para área-teste 2

5 RESULTADOS E DISCUSSÃO

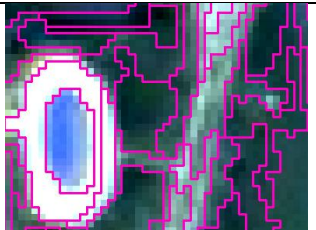


Neste capítulo são apresentados, avaliados e comparados os resultados do método utilizado nas classificações da cobertura e uso do solo nas três áreas-teste, a partir do uso de imagens do satélite WorldView II.

5.1 Segmentações

O processo de segmentação precedeu às classificações por região, com o algoritmo Bhattacharyya, e baseadas em objetos.

Na classificação por região, as segmentações foram geradas de acordo com limiares de área e similaridade. O limiar de área exerceu influência no número de polígonos gerados, assim, os valores escolhidos foram os que melhor representaram as regiões de cada área-teste. O limiar de similaridade buscou agrupar cada região de acordo com a distância euclidiana mínima entre as médias das regiões. A boa combinação destes limiares influenciou diretamente na qualidade das classificações, pois seus limites representaram os limites das classes da classificação final. As combinações de similaridade e área que obtiveram os melhores resultados estão listados no Quadro 4.

Quadro 4 - Combinações de similaridade e área encontradas para cada área-teste

Parâmetros	Exemplo
Área-teste: 1 Similaridade: 25 Área: 30	
Área-teste 2 Similaridade: 25 Área: 30	
Área-teste 3 Similaridade: 15 Área: 20	

Na classificação baseada em objetos, os parâmetros das segmentações foram inseridos no operador Terra Aida_Baatz_Segmenter, no sistema InterIMAGE, onde foram definidos valores para pesos relativos às bandas do sistema sensor Worldview II, compacidade, cor e escala. O parâmetro “pesos das bandas” define a relevância de cada banda para a classificação. Não foram calibrados os pesos das bandas espectrais, desta forma, atribuiu-se para todas as bandas do sensor o peso 1, dando a mesma relevância a todas as bandas na classificação; a “compacidade” representou a forma de agrupamento dos *pixels* de cada objeto, um maior valor significa objetos mais compactos, ou seja, mais agrupados, um menor valor representa objetos menos compactos, ou seja, mais espalhados; o parâmetro “cor” refere-se aos valores espectrais de cada objeto, já que é a soma ponderada dos desvios-padrão de cada banda; o valor da “escala” definirá o tamanho de cada objeto. Com estes parâmetros ajustados (Tabelas 6, 7 e 8) foi possível uma melhor separação de cada classe.

Tabela 6 - Parâmetros utilizados para a segmentação das classes da área-teste 1

Classe	Pesos das bandas	Compacidade	Cor	Escala
Asfalto	-	-	-	-
Cobertura de Cerâmica Clara	1,1,1,1,1,1,1,1	0.8	0.4	110
Cobertura de Cerâmica	1,1,1,1,1,1,1,1	0.8	0.4	110
Cobertura de Cimento Claro	1,1,1,1,1,1,1,1	0.8	0.4	80
Cobertura de Cimento Médio	1,1,1,1,1,1,1,1	0.8	0.4	110
Cobertura de Cimento Verde	1,1,1,1,1,1,1,1	0.8	0.4	110
Piscina	1,1,1,1,1,1,1,1	0.9	0.2	50
Solo Exposto	1,1,1,1,1,1,1,1	0.8	0.1	80
Sombra	1,1,1,1,1,1,1,1	0.1	0.8	80
Vegetação Arbórea	1,1,1,1,1,1,1,1	0.8	0.4	70
Vegetação Rasteira	1,1,1,1,1,1,1,1	0.5	0.5	80

Tabela 7 - Parâmetros utilizados para a segmentação das classes da área-teste 2

Classe	Pesos das bandas	Compacidade	Cor	Escala
Asfalto	-	-	-	-
Cobertura de Cerâmica	1,1,1,1,1,1,1,1	0.8	0.4	80
Cobertura de Cimento Claro	1,1,1,1,1,1,1,1	0.8	0.4	80
Cobertura de Cimento Escuro	1,1,1,1,1,1,1,1	0.8	0.4	90
Cobertura de Cimento Médio	1,1,1,1,1,1,1,1	0.8	0.4	90
Cobertura Metálica	1,1,1,1,1,1,1,1	0.8	0.4	90
Solo Exposto	1,1,1,1,1,1,1,1	0.8	0.1	80
Sombra	1,1,1,1,1,1,1,1	0.1	0.8	80
Vegetação Arbórea	1,1,1,1,1,1,1,1	0.4	0.8	70
Vegetação Rasteira	1,1,1,1,1,1,1,1	0.5	0.5	80

Tabela 8 - Parâmetros utilizados para a segmentação das classes da área-teste 3

Classe	Pesos das bandas	Compacidade	Cor	Escala
Asfalto	-	-	-	-
Cobertura de Cerâmica Clara	1,1,1,1,1,1,1	0.8	0.4	90
Cobertura de Cerâmica	1,1,1,1,1,1,1	0.8	0.4	90
Cobertura de Cimento Claro	1,1,1,1,1,1,1	0.8	0.4	90
Cobertura de Cimento Escuro	1,1,1,1,1,1,1	0.8	0.4	90
Cobertura de Cimento Médio	1,1,1,1,1,1,1	0.8	0.4	90
Cobertura Metálica	1,1,1,1,1,1,1	0.8	0.4	90
Piscina	1,1,1,1,1,1,1	0.8	0.2	50
Solo Exposto	1,1,1,1,1,1,1	0.8	0.1	80
Sombra	1,1,1,1,1,1,1	0.1	0.8	80
Vegetação Arbórea	1,1,1,1,1,1,1	0.4	0.8	70
Vegetação Rasteira	1,1,1,1,1,1,1	0.5	0.5	80

Não houve necessidade da inserção de parâmetros para a classe Asfalto, uma vez que o critério de separação desta classe não partiu de uma segmentação, e sim da utilização dos arquivos vetoriais de quadras e arruamentos no formato ESRI *Shapefile*, elaborados pela TERRACAP.

No nó Vegetação Rasteira, em todas as classificações baseadas em objetos, também não foram inseridos parâmetros de segmentação, pois estes foram herdados de seu nó pai (Vegetação), já que o nó Vegetação Rasteira recebeu o operador holístico Dummy Top-Down. Quando se emprega este operador em algum nó filho, ele utiliza apenas a região geográfica de seu nó pai, assim, os parâmetros de segmentação da classe Vegetação Rasteira são os mesmos do nó “Vegetação” na rede semântica.

5.2 Regras de decisão para separação de classes no InterIMAGE

A separação de classes no InterIMAGE foi feita por meio de inserção de regras de decisão dentro de cada nó da rede semântica. Os atributos que foram explorados entre as bandas e utilizados nas regras de decisão foram: razão, divisão, média, soma, desvio-padrão, valores máximos de *pixel* e brilho. Estes parâmetros foram calculados sempre utilizando o valor médio do atributo dentro do objeto (segmento). Nas figuras 19 a 24 são apresentadas as regras de decisão elaboradas para individualizar cada classe. Estas regras foram inseridas

apenas nas classes que foram segmentadas, assim, a classe Asfalto não recebeu regras de decisão. Estas regras foram utilizadas para separar as classes das três áreas-teste.

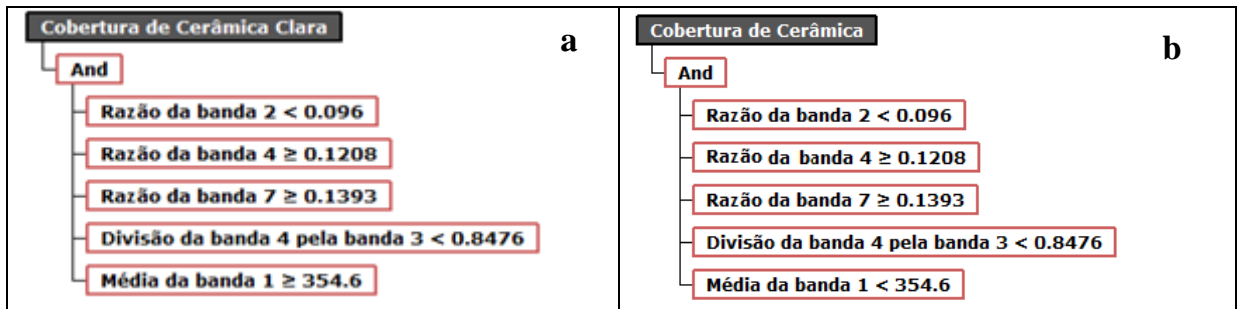


Figura 19 - Regras de decisão para as classes Cobertura de Cerâmica Clara (a) e Cobertura de Cerâmica (b)

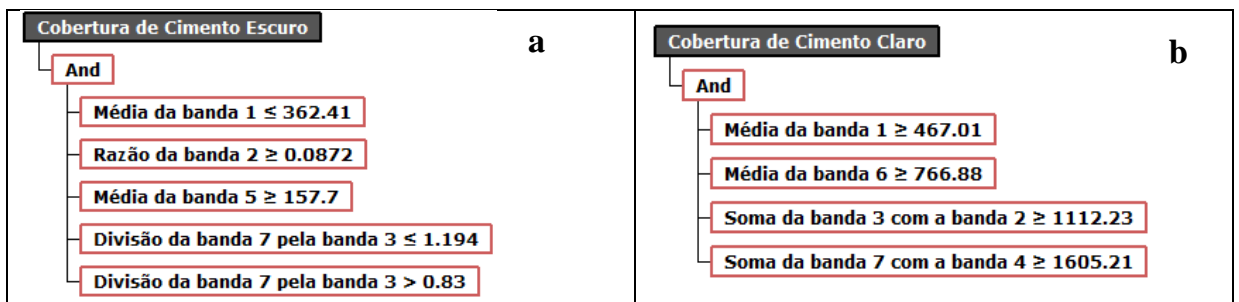


Figura 20 - Regras de decisão para as classes Cobertura de Cimento Escuro (a) e Cobertura de Cimento Claro (b)

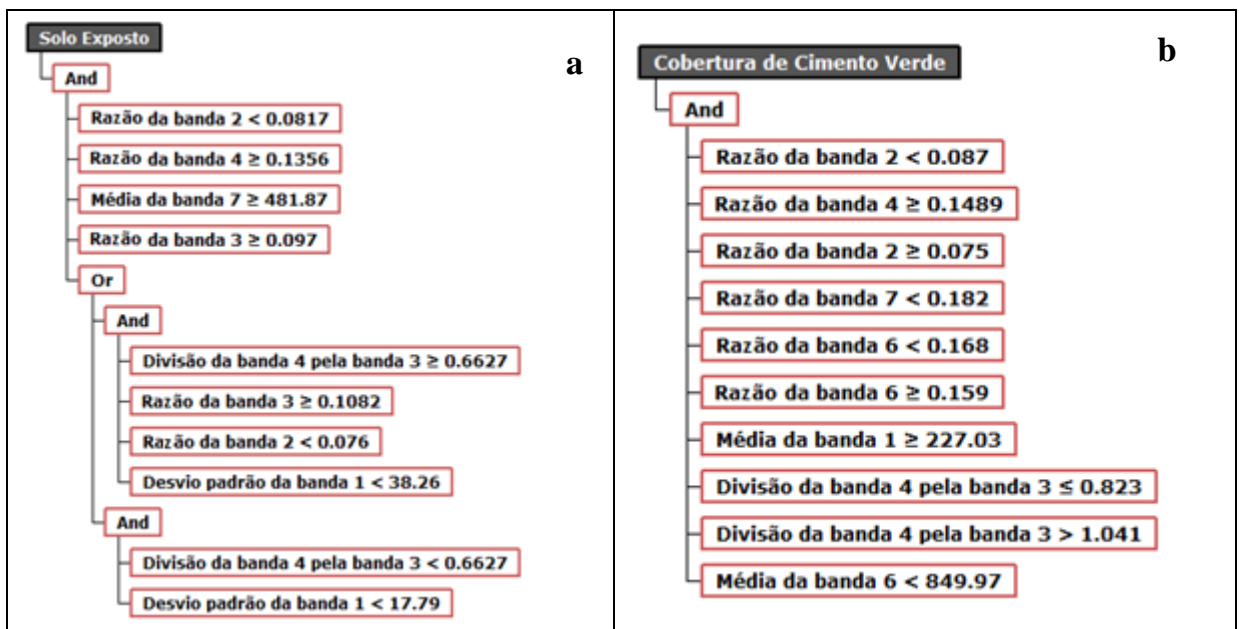


Figura 21 - Regras de decisão para as classes Solo Exposto (a) e Cobertura de Cimento Verde (b)




Figura 22 - Regras de decisão para as classes Piscina (a) e Sombra (b)

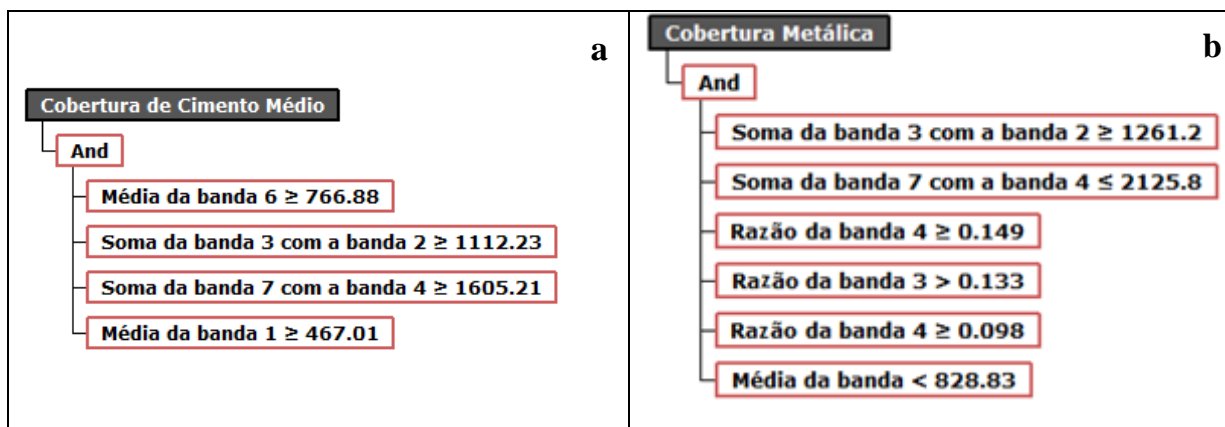


Figura 23 - Regras de decisão para as classes Cobertura de Cimento Médio (a) e Cobertura Metálica (b)

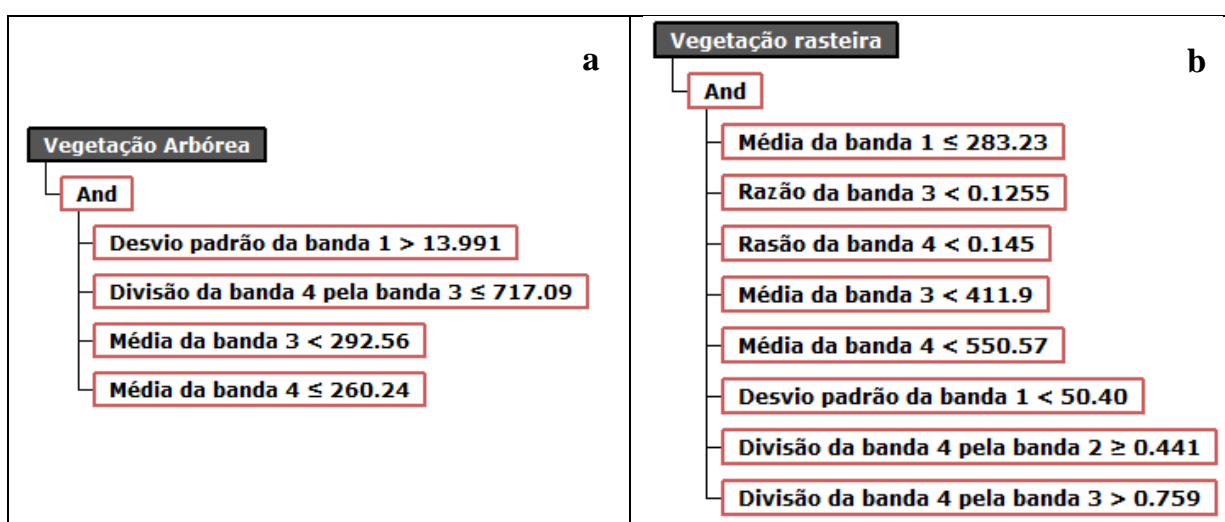


Figura 24 - Regras de decisão para as classes Vegetação Arbórea (a) e Vegetação Rasteira (b)

Estas regras foram definidas a partir da análise dos valores espectrais nas diferentes bandas da imagem WorldView II e de características específicas de cada alvo, isso foi feito por meio das respostas encontradas no recurso *Analysis Manager* do *software* InterIMAGE, que permitiu o refinamento dos resultados por meio da análise de gráficos de histogramas. As figuras 25 e 26 apresentam exemplos do recurso *Analysis Manager*, onde se pode observar um limiar entre duas modas de cada histograma, assim, o recurso permitiu um fatiamento do histograma separando as classes. No primeiro histograma (Figura 25), com os valores digitais da imagem, foi calculada a razão da banda 4, onde nota-se que, ao fatiar o histograma entre as duas modas, a classe Vegetação Rasteira é separada das demais. A figura 26 retrata o fatiamento do histograma dos valores resultantes da divisão dos números digitais da banda 3 pela banda 2, onde a classe Cobertura de Cerâmica separa-se das demais.




Figura 25 - Separação da classe Vegetação Rasteira das demais, através do fatiamento de histograma




Figura 26 - Separação da classe Cobertura de Cerâmica das demais, através do fatiamento de histograma

Os limiares entre modas encontrados por meio da análise dos histogramas foram inseridos nas regras de decisões utilizadas na etapa *top-down*, onde a cena foi particionada em sub-regiões (segmentos) que gerou hipóteses de objetos (atribuir classes aos segmentos), estas hipóteses foram classificadas nas etapas *bottom-up*. A etapa *bottom-up* avaliou as hipóteses de objetos, validando-as ou não e resolvendo eventuais conflitos espaciais, cuja resolução se deu por meio de atribuições de valores de pertinência para cada classe. Com os valores de pertinência atribuiu-se uma importância à classe em relação às demais, assim, quando houve conflitos espaciais, ou seja, quando um segmento foi classificado em duas classes diferentes, este segmento ficou apenas na classe que apresentou uma importância (pertinência) maior. Este valor foi definido para as classes levando-se em consideração a qualidade de separação de cada uma delas e a quantidade de segmentos classificados de forma errada. A Tabela 9 apresenta os valores de pertinência utilizados em cada classe para cada área-teste.

Tabela 9 - Valores de pertinência de cada classe para cada área-teste

Classes	Área-teste 1	Área-teste 2	Área-teste 3
Asfalto	3	3	3
Cobertura Cerâmica Clara	7	-	8
Cobertura Cerâmica	6	2	7

Cobertura Cimento Escuro	-	2	3
Cobertura Cimento Claro	8	2	3
Cobertura Cimento Médio	5	2	2
Cobertura Cimento Verde	6	-	-
Cobertura Metálica	-	6	4
Piscina	4	-	3
Solo Exposto	8	5	8
Sombra	3	5	8
Vegetação Arbórea	3	3	3
Vegetação Rasteira	2	2	2

5.3 Redução da dimensão espectral por *Minimum Noise Fraction* (MNF) utilizada na classificação SAM

Para todas as áreas-teste, observou-se uma concentração do sinal nas quatro primeiras componentes MNF (Figura 27). Isto pode ser notado, também, pela comparação visual entre as bandas MNF apresentadas na figura 28, para a área-teste 1, onde a imagem foi submetida a uma transformação sequencial que ordenou os dados de acordo com a relação sinal/ruído (SNR) (GREEN *et al.*, 1988), resultando em um novo conjunto de bandas que foi ordenado segundo os autovalores de variância das bandas. A ordem crescente das bandas implica em aumento do nível de ruído, indicado pela menor variância. (RUDORFF, 2006).




Figura 27 - Autovalores observados pela transformação MNF para dados do Worldview II na área-teste 1




Figura 28 - Componentes da transformação MNF da área-teste 1

5.4 Mapas temáticos e avaliação das classificações

Neste tópico são apresentados os mapas temáticos gerados a partir das classificações por *pixel* (Maxver e SAM), por região (Bhattacharyya) e baseadas em objetos para as três áreas-teste e suas respectivas matrizes de confusão. Serão ainda discutidos os resultados das avaliações de cada classificação para cada área-teste pela apresentação das matrizes de confusão.

Visualmente, nota-se que as classificações baseadas em objetos apresentaram melhores resultados quando comparadas às classificações por *pixel* e por região.

A acurácia dos resultados das classificações foi avaliada por meio de matrizes de confusão de onde foram extraídos os coeficientes de concordância para a avaliação da concordância para acurácia total: índice *Kappa* (COHEN, 1960), índice *Tau* (KLECKA, 1980) e Exatidão Global (HELLDEN *et al.*, 1980). Foi calculado o número de amostragens em uma distribuição multinominal (CONGALTON & GREEN, 1999), utilizando-se o *pixel* como referência e unidade amostral.

No mapa temático resultante da classificação por região (Bhattacharyya) para a área-teste 1 (Figura 29), visualmente nota-se uma boa separação das classes. Quando se analisa a matriz de confusão (Tabela 10), percebe-se que as classes Cobertura de Cimento Claro e Piscina foram as que obtiveram menos misturas com as demais, e, ainda, nota-se que a classe que mais se misturou foi a Solo Exposto. Estas misturas ocorreram principalmente com as classes Asfalto, Cobertura de Cerâmica, Cobertura de Cimento Claro e, principalmente, Cobertura de Cerâmica Clara. As porcentagens de exatidão total para esta classificação atingiram valores de exatidão global, índice *Kappa* e índice *Tau* de 80,6%, 78,3% e 78,7%, respectivamente, tendo o índice *Kappa* ótimo resultado, segundo Landis e Koch (1977).

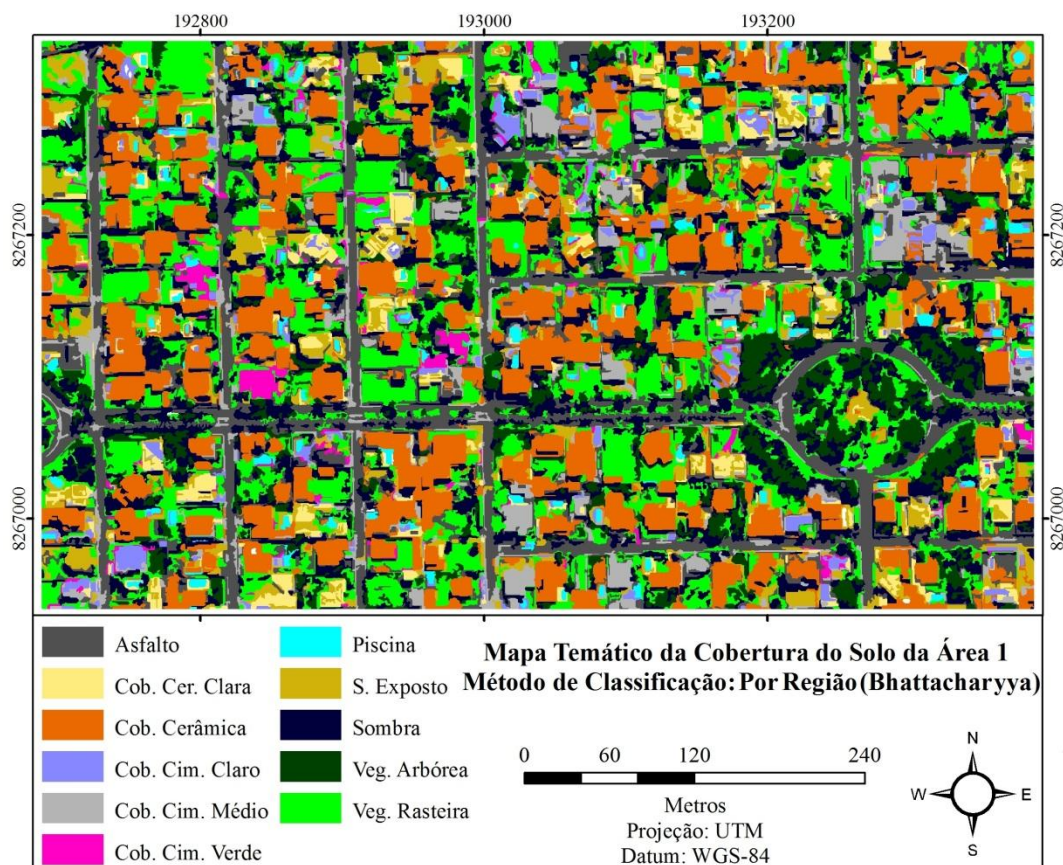


Figura 29 - Mapa temático resultante da classificação por região (Bhattacharyya) para a área-teste 1

Tabela 10 - Matriz de confusão da classificação por região (Bhattacharyya) para a área-teste 1

Classificação \ Referência (Verdade)												
	Asfalto	Cobertura de Cerâmica Clara	Cobertura de Cerâmica	Cobertura de Cimento Claro	Cobertura de Cimento Médio	Cobertura de Cimento Verde	Piscina	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	Total
Asfalto	64				8	1		2	4	1	2	82
Cobertura de Cerâmica Clara		26		11		1		3				41
Cobertura de Cerâmica		1	81	4			1	7			2	96
Cobertura de Cimento Claro				34								34
Cobertura de Cimento Médio	10				33		1					44
Cobertura de Cimento Verde					1	16		1				18
Piscina							35					35
Solo Exposto	2	29	3	2	1			36			1	74
Sombra	4		1						58	10	3	76
Vegetação Arbórea									1	60	5	66
Vegetação Rasteira	1							2	2	4	107	116
Total	81	56	85	51	43	18	37	51	65	75	120	682

No mapa temático resultante da classificação por região (Bhattacharyya), para a área-teste 2 (Figura 30), visualmente nota-se uma boa separação das classes, com destaque para a classe Cobertura de Cimento Claro que teve poucas misturas e que mais contribuiu para o aumento das porcentagens dos coeficientes de concordância total.

Ao analisar a matriz de confusão (Tabela 11) nota-se uma maior mistura da classe Asfalto com a classe Cobertura de Cimento Escuro, assim como da classe Cobertura de Cerâmica com a classe Solo Exposto. Os erros destas classes foram os que mais contribuíram para a redução das porcentagens dos coeficientes de concordância de exatidão total, isso pode ser explicado, nesta classificação, pelo fato da semelhança espectral destes alvos.

As porcentagens de exatidão total para esta classificação atingiram valores de exatidão global, índice *Kappa* e índice *Tau* de 84,3%, 82,2% e 82,6%, respectivamente. *Kappa* com excelente resultado, segundo Landis e Koch (1977).

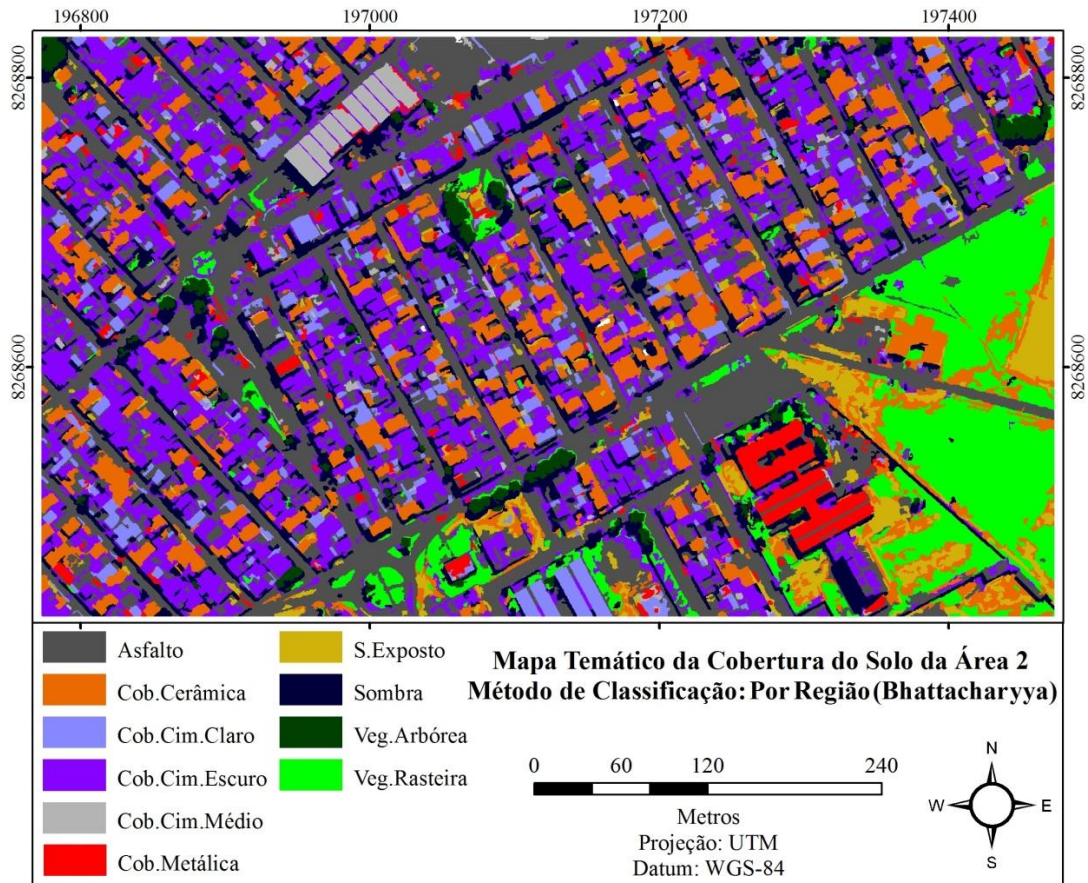


Figura 30 - Mapa temático resultante da classificação por região (Bhattacharyya) para a área-teste 2

Tabela 11 - Matriz de confusão da classificação por região (Bhattacharyya) para a área-teste 2

Classificação \ Referênci (Verdade)											
	Asfalto	Cobertura de Cerâmica	Cobertura de Cimento Claro	Cobertura de Cimento Escuro	Cobertura de Cimento Médio	Cobertura Metálica	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	Total
Asfalto	79			14	13	2	5			2	115
Cobertura de Cerâmica		89	1		1		22			2	115
Cobertura de Cimento Claro			77			1					78
Cobertura de Cimento Escuro	5			84	1					5	95
Cobertura de Cimento Médio	1				14						15
Cobertura Metálica	1		5			23					29
Solo Exposto	3	1					41			1	46
Sombra		1		1			2	73	9	1	87
Vegetação Arbórea									33	3	36
Vegetação Rasteira							1		1	51	53
Total	89	91	83	99	29	26	71	73	43	65	669

Visualmente nota-se uma boa separação das classes do mapa temático resultante da classificação por região (Bhattacharyya) para a área-teste 3 (Figura 31). Analisando a matriz de confusão (Tabela 12) nota-se que as misturas se comportaram de forma semelhante à classificação por região para a área-teste 2, já que suas principais misturas se deram na classe Asfalto com a classe Cobertura de Cimento Escuro. As classes Cobertura de Cerâmica e Solo Exposto foram as que mais contribuíram para a redução das porcentagens dos coeficientes de concordância total, essa mistura se deu pelas semelhanças espectrais destes alvos. Em contrapartida, a classe mais responsável pelo aumento das porcentagens de exatidão total foi a classe Piscina, já que obteve a melhor separação em relação às demais.

As porcentagens de exatidão total para esta classificação atingiram valores de exatidão global, índice *Kappa* e índice *Tau* de 82,1%, 80,3% e 80,5%, respectivamente. *Kappa* com excelente resultado, segundo Landis e Koch (1977).

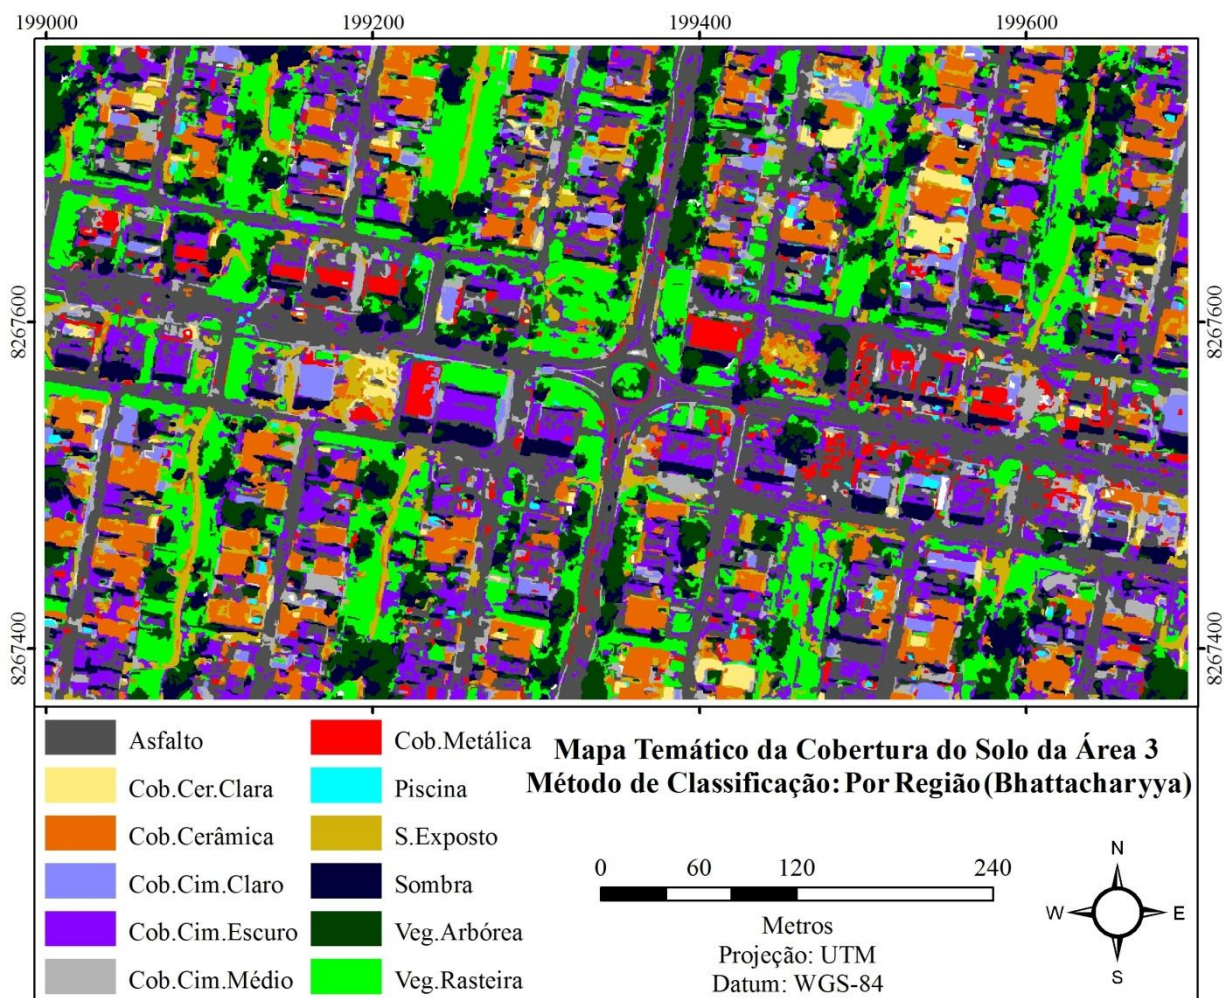


Figura 31 - Mapa temático resultante da classificação por região (Bhattacharyya) para a área-teste 3

Tabela 12 - Matriz de confusão da classificação por região (Bhattacharyya) para a área-teste 3

Referência (Verdade) Classificação	Asfalto	Cobertura de Cerâmica Clara	Cobertura de Cerâmica Clara	Cobertura de Cimento Claro	Cobertura de Cimento Escuro	Cobertura de Cimento Médio	Cobertura Metálica	Piscina	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	Total
Asfalto	52			1	18	3		1	3	1		1	80
Cobertura de Cerâmica Clara		25		6					3				34
Cobertura de Cerâmica		2	63	1					4				70
Cobertura de Cimento Claro		3		52		4	1						60
Cobertura de Cimento Escuro	11				55	1				1		2	70
Cobertura de Cimento Médio	4		1	1		16			1			1	24
Cobertura Metálica	1			2		1	19						23
Piscina								21					21
Solo Exposto			7						47				54
Sombra	1									64	6		71
Vegetação Arbórea										4	52	4	60
Vegetação Rasteira	1	1			1				3		6	54	66
Total	70	31	71	63	74	25	20	22	61	70	64	62	633

Visualmente nota-se uma boa separação das classes do mapa temático resultante da classificação baseada em objeto para a área-teste 1 (Figura 32), com destaque para o formato dos objetos, que representou com maior proximidade com o formato real do objeto. Isso se deu pelo fato da utilização do segmentador desenvolvido por Baatz e Schäpe (2000), o qual permitiu a inserção de parâmetros específicos para melhorar o formato do objeto.

Ao analisar a matriz de confusão (Tabela 13), nota-se que as classes que mais contribuíram para o aumento das porcentagens dos coeficientes de concordância total foram Asfalto, Cobertura de Cimento Verde e Piscina. Em contrapartida, a classe que mais contribuiu para a redução das porcentagens dos coeficientes de concordância total foi a classe Cobertura de Cerâmica Clara, o que pode ser explicado pelo fato de sua semelhança espectral com a classe de Cobertura de Cimento Claro, além do número reduzido de amostras para esta classe, fazendo com que qualquer erro tenha valor significativo.

As outras classes também tiveram algumas misturas, entretanto, a quantidade de acerto para estas classes foi suficiente para manter as porcentagens em um patamar alto. As porcentagens de exatidão total para esta classificação atingiram valores de exatidão global, índice *Kappa* e índice *Tau* de 87,5%, 86,0% e 86,3%, respectivamente. *Kappa* com excelente resultado, segundo Landis e Koch (1977).

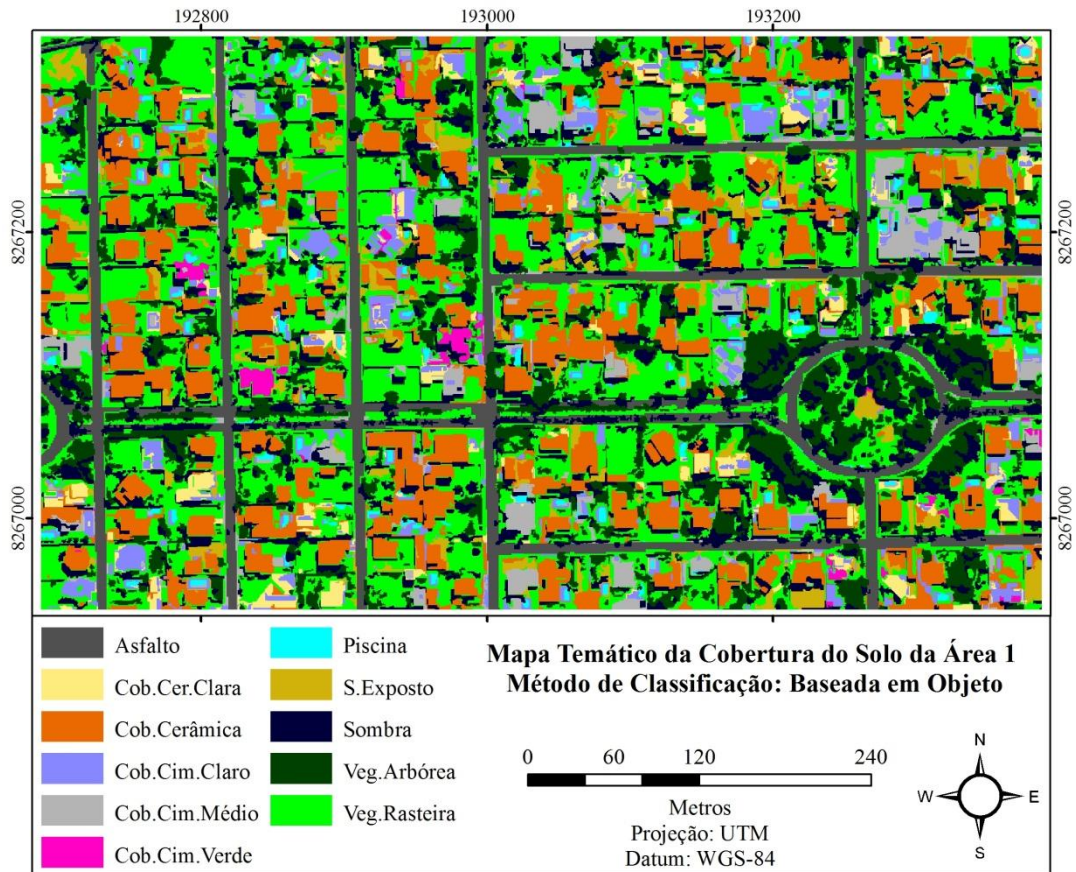


Figura 32 - Mapa temático resultante da classificação baseada em objeto para a área-teste 1

Tabela 13 - Matriz de confusão da classificação baseada em objeto para a área-teste 1

Classificação \ Referênci (Verdade)											Total	
	Asfalto	Cobertura de Cerâmica Clara	Cobertura de Cerâmica	Cobertura de Cimento Claro	Cobertura de Cimento Médio	Cobertura de Cimento Verde	Piscina	Solo Exposto	Sombra	Vegetação Arbórea		Vegetação Rasteira
Asfalto	77											77
Cobertura de Cerâmica Clara		36	1	7				2				46
Cobertura de Cerâmica		8	80	1	1			4			1	95
Cobertura de Cimento Claro		9		43				1				53
Cobertura de Cimento Médio				1	38	3	2					44
Cobertura de Cimento Verde						15						15
Piscina							35					35
Solo Exposto		2	3					33			1	39
Sombra	3	1	1		1				61		1	68
Vegetação Arbórea	1								2	70	8	81
Vegetação Rasteira					2			11	2	5	109	129
Total	81	56	85	51	43	18	37	51	65	75	120	682

A classificação baseada em objeto para a área-teste 2 também obteve uma boa separação das classes (Figura 33), com destaque para a classe Asfalto, que obteve bons índices em virtude da utilização de um arquivo *shapefile* que serviu como máscara.

Ao analisar a matriz de confusão (Tabela 14) nota-se que a classe que obteve melhor separação das demais foi a Cobertura Metálica, em função de sua pouca mistura com as demais, apesar do reduzido número de amostras de referência. As classes Cobertura de Cimento Claro e Cobertura de Cimento Escuro também tiveram uma boa separação, além de terem contribuído significativamente para o aumento das porcentagens dos coeficientes de concordância total.

As classes que mais contribuíram para a redução das porcentagens dos coeficientes de concordância total, calculados a partir da matriz de confusão, foram Cobertura de Cerâmica e Solo Exposto, mais uma vez a semelhança espectral foi a causa dessa mistura.

As porcentagens de exatidão total para esta classificação atingiram valores de exatidão global, índice *Kappa* e índice *Tau* de 90,6%, 89,4% e 89,5%, respectivamente. *Kappa* com excelente resultado, segundo Landis e Koch (1977).

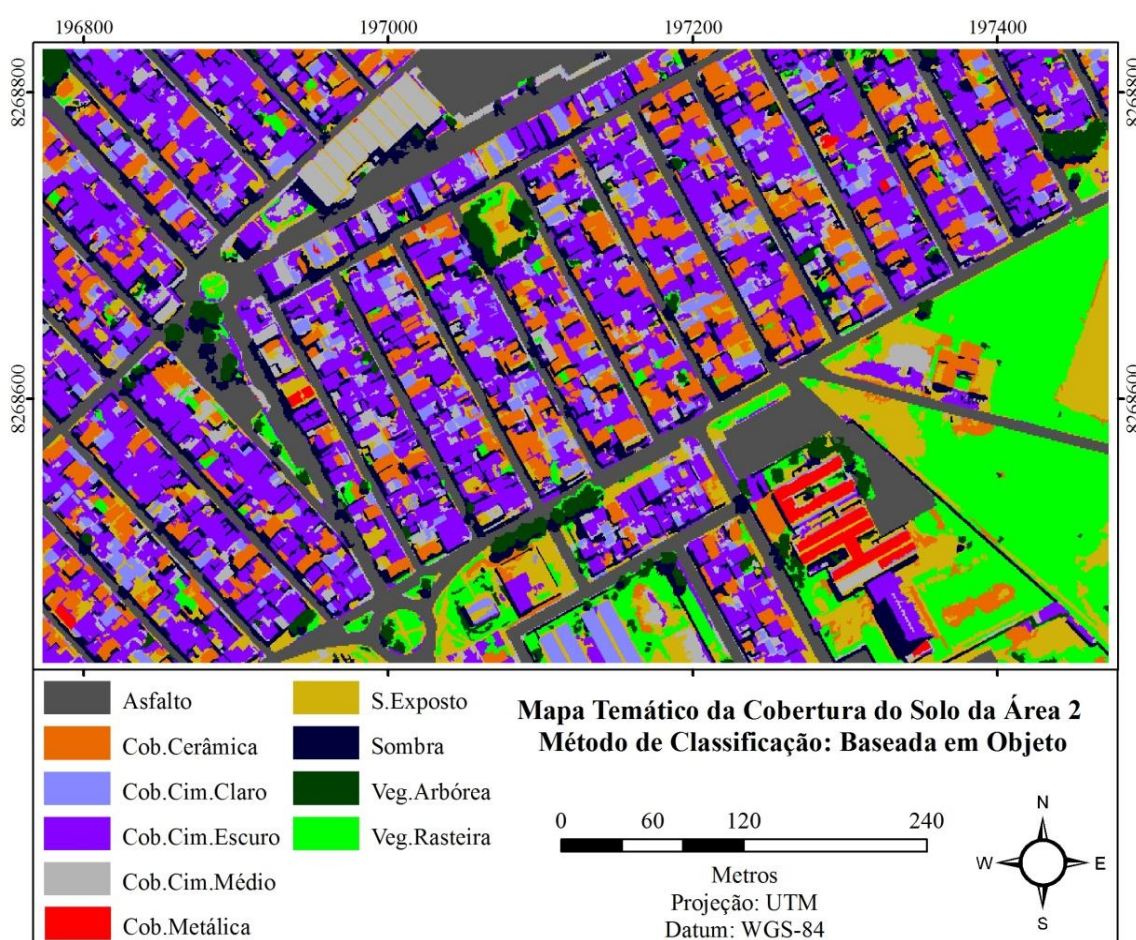


Figura 33 - Mapa temático resultante da classificação baseada em objeto para a área-teste 2

Tabela 14 - Matriz de confusão da classificação baseada em objeto para a área-teste 2

Referência (Verdade)	Asfalto	Cobertura de Cerâmica	Cobertura de Cimento Claro	Cobertura de Cimento Escuro	Cobertura de Cimento Médio	Cobertura Metálica	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	Total
Classificação											
Asfalto	89			1			2	2		2	96
Cobertura de Cerâmica		81					14			1	96
Cobertura de Cimento Claro			82			2					84
Cobertura de Cimento Escuro		2		93	1						96
Cobertura de Cimento Médio		1	1		26	2					30
Cobertura Metálica						19					19
Solo Exposto		4			3	2	52	1	1	2	65
Sombra		1		5			2	70			78
Vegetação Arbórea									42	8	50
Vegetação Rasteira		2					1			52	55
Total	89	91	83	99	30	25	71	73	43	65	669

A classificação baseada em objeto para a área-teste 3, visualmente, obteve uma boa separação das classes (Figura 34), com destaque para a classe Piscina, que foi a que menos se misturou com as demais. As classes que mais contribuíram para o aumento das porcentagens dos coeficientes de concordância total foram Asfalto, Cobertura de Cimento Claro e Cobertura de Cimento Escuro.

A classe que mais se misturou com as demais nesta classificação foi Cobertura de Cimento Médio (Tabela 15), que se misturou principalmente com a Cobertura de Cimento Claro, o que pode ser explicado em função de seu semelhante material de fabricação, entretanto, esta classe não teve muita influência na redução das porcentagens dos coeficientes de concordância total pelo fato de seu reduzido número de amostras.

As classes que mais contribuíram para a redução das porcentagens dos coeficientes de concordância total foram Cobertura de Cerâmica e Solo Exposto, a semelhança espectral foi a causa dessa mistura.

As porcentagens de exatidão total para esta classificação atingiram valores de exatidão global, índice *Kappa* e índice *Tau* de 88,5%, 87,3% e 87,4%, respectivamente. *Kappa* com excelente resultado, segundo Landis e Koch (1977).

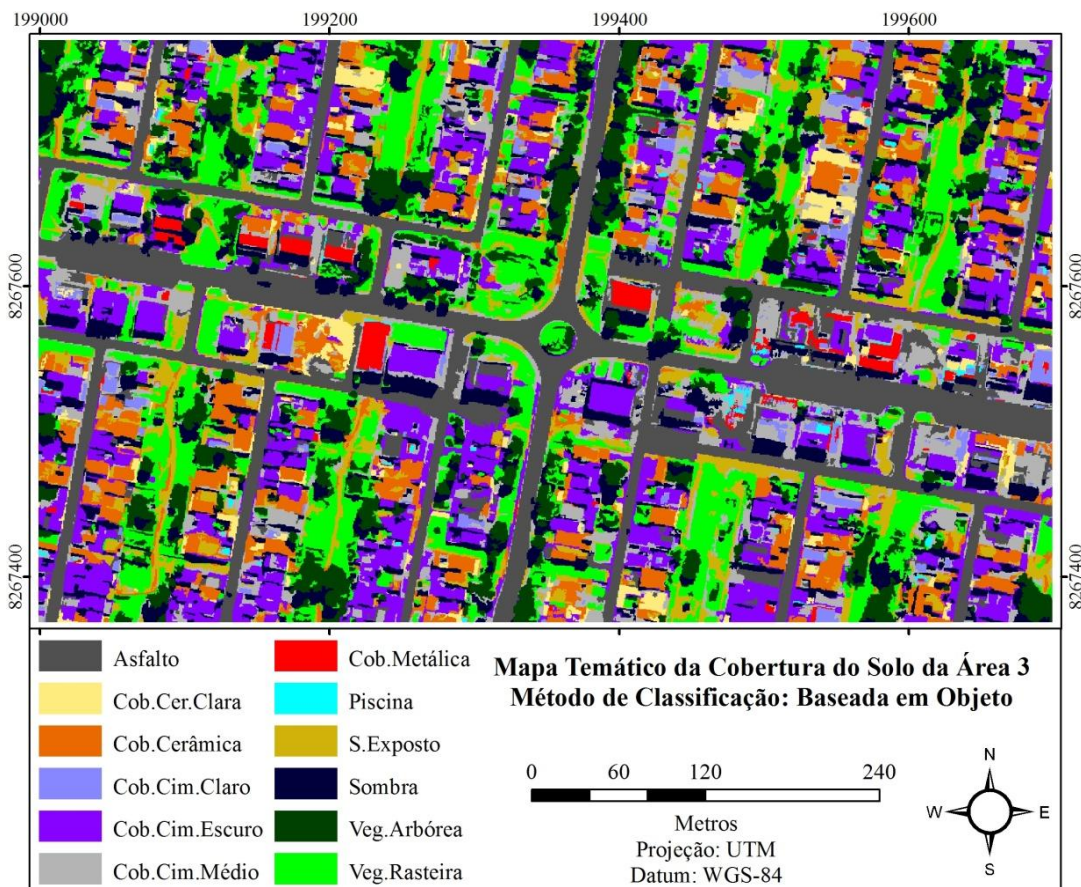


Figura 34 - Mapa temático resultante da classificação baseada em objeto para a área-teste 3

Tabela 15 - Matriz de confusão da classificação baseada em objeto para a área-teste 3

Classificação \ Referência (Verdade)													
	Asfalto	Cobertura de Cerâmica Clara	Cobertura de Cerâmica	Cobertura de Cimento Claro	Cobertura de Cimento Escuro	Cobertura de Cimento Médio	Cobertura Metálica	Piscina	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	Total
Asfalto	69				4	2							75
Cobertura de Cerâmica Clara		27	1	2					2				32
Cobertura de Cerâmica			65						8				73
Cobertura de Cimento Claro		3		49									52
Cobertura de Cimento Escuro				1	68	1			1			2	73
Cobertura de Cimento Médio		2		5	1	23	1	6	2			1	41
Cobertura Metálica				4			18	2					24
Piscina								14					14
Solo Exposto	1		5						48			1	55
Sombra										70	1	1	72
Vegetação Arbórea											57	7	64
Vegetação Rasteira					1						5	52	58
Total	70	32	71	61	74	26	19	22	61	70	63	64	633

Visualmente, o mapa temático resultante da classificação por *pixel* (Maxver) para a área-teste 1 (Figura 35) apresenta misturas quando comparado aos anteriores, entretanto, este efeito que desagrada aos olhos, causado por *pixels* isolados em outras classes e conhecido como efeito “sal e pimenta”, não foi suficiente para deixar os coeficientes de concordância com porcentagens reduzidas, superando, inclusive, a classificação por região em todas as área-teste.

As classes de Cobertura de Cimento Verde, Piscina e Vegetação Rasteira foram as com melhor separação das demais, entretanto, a classe que mais contribuiu para o aumento da porcentagem dos coeficientes de concordância foi Vegetação Rasteira, isso aconteceu devido à classe possuir um número elevado de amostras de referência com poucas misturas com as demais (Tabela 16).

As classes que mais contribuíram para a redução das porcentagens dos coeficientes de concordância total foram Cobertura de Cerâmica e Solo Exposto, devido à semelhança espectral.

As porcentagens de exatidão total para esta classificação atingiram valores de exatidão global, índice *Kappa* e índice *Tau* de 83,7%, 81,8% e 82,1%, respectivamente. *Kappa* com excelente resultado, segundo Landis e Koch (1977).

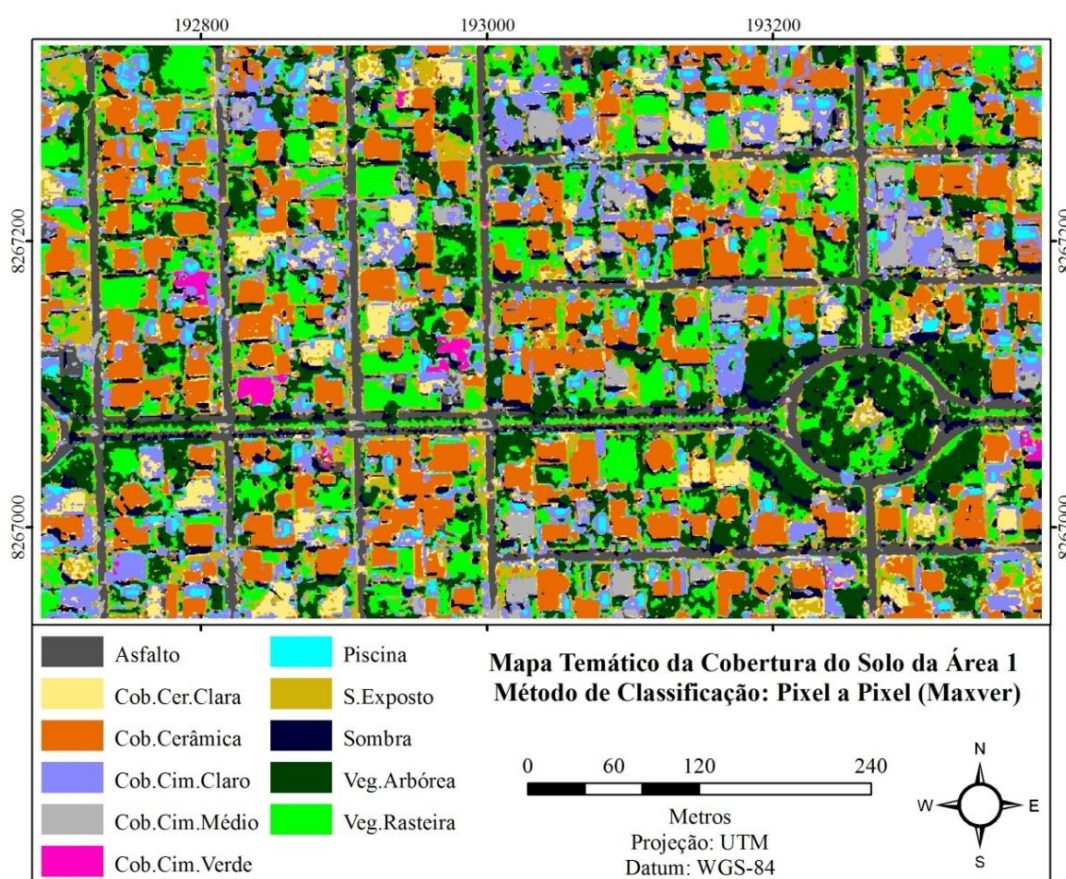


Figura 35 - Mapa temático resultante da classificação por *pixel* (Maxver) para a área-teste 1

Tabela 16 - Matriz de confusão da classificação por *pixel* (Maxver) para a área-teste 1

Classificação \ Referência (Verdade)	Asfalto	Cobertura de Cerâmica Clara	Cobertura de Cerâmica	Cobertura de Cimento Claro	Cobertura de Cimento Médio	Cobertura de Cimento Verde	Piscina	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	Total
	Asfalto	67				5				3		
Cobertura de Cerâmica Clara		44	1	10				7				62
Cobertura de Cerâmica			82		2			6	2		1	93
Cobertura de Cimento Claro	2	3		40	4	4		5			1	59
Cobertura de Cimento Médio	6			1	29							36
Cobertura de Cimento Verde						15						15
Piscina							37		1			38
Solo Exposto	2	9	1		1			33			7	53
Sombra	1		1		1				55		1	59
Vegetação Arbórea	2								4	75	16	97
Vegetação Rasteira	1										94	95
Total	81	56	85	51	43	18	37	51	65	75	120	682

No mapa temático resultante da classificação por *pixel* (Maxver) para a área-teste 2 (Figura 36), observa-se que a classificação obteve uma boa separação das classes, apesar do visível número de *pixels* isolados em outras classes (efeito “sal e pimenta”).

Observando a matriz de confusão (Tabela 16), nota-se que as classes de Cobertura de Cimento Escuro, Cobertura Metálica e Vegetação Rasteira foram as com melhor separação das demais e também as que mais contribuíram para o aumento das porcentagens dos coeficientes de concordância total devido ao número de amostras de referência e às poucas misturas com outras classes.

As classes que obtiveram maior mistura com as demais e, conseqüentemente, mais contribuíram para a redução das porcentagens dos coeficientes de concordância total foram Cobertura de Cerâmica e Solo Exposto, em que a semelhança espectral mais uma vez exerceu grande influência.

As porcentagens de exatidão total para esta classificação atingiram valores de exatidão global, índice *Kappa* e índice *Tau* de 88,6%, 87,1% e 87,4%, respectivamente. *Kappa* com excelente resultado, segundo Landis e Koch (1977).

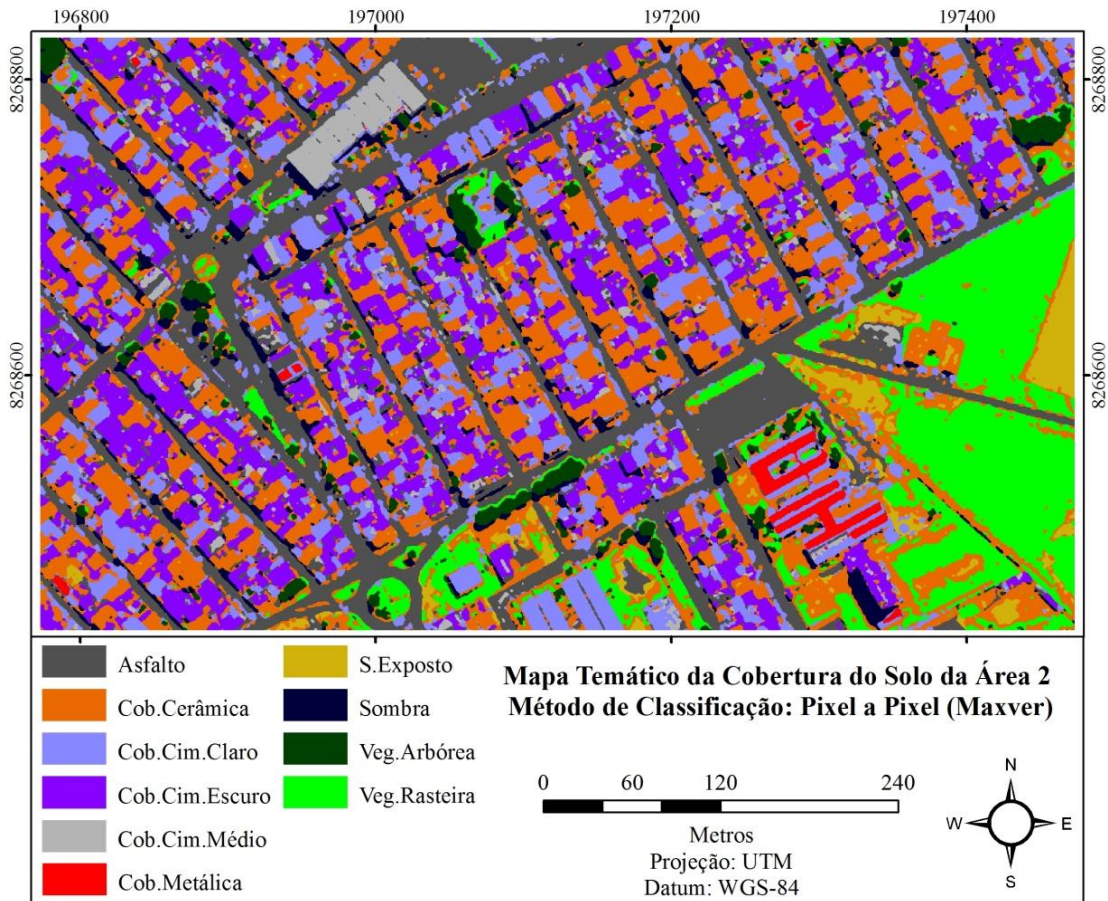


Figura 36 - Mapa temático resultante da classificação por *pixel* (Maxver) para a área-teste 2

Tabela 17 - Matriz de confusão da classificação por *pixel* (Maxver) para a área-teste 2

Classificação \ Referência (Verdade)	Asfalto	Cobertura de Cerâmica	Cobertura de Cimento Claro	Cobertura de Cimento Escuro	Cobertura de Cimento Médio	Cobertura Metálica	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	Total
	Asfalto	83			3	3		3	1		1
Cobertura de Cerâmica	1	89		3			23	7		2	125
Cobertura de Cimento Claro	3		86			5	5	1		1	101
Cobertura de Cimento Escuro				90							90
Cobertura de Cimento Médio	2			1	24	1					28
Cobertura Metálica						19					19
Solo Exposto		2					39				41
Sombra				3			1	63			67
Vegetação Arbórea									42	3	45
Vegetação Rasteira									1	58	59
Total	89	91	86	100	27	25	71	72	43	65	669

O mapa temático resultante da classificação por *pixel* (Maxver) para a área-teste 3 (Figura 37), também apresentou uma boa separação dos alvos, com destaque para as classes Asfalto, Cobertura Cimento Escuro, Cobertura Cimento Claro e Sombra, que foram as que mais contribuíram para o aumento das porcentagens dos coeficientes de concordância total, pois, além de se misturarem pouco com as demais, tiveram maior quantidade de amostras de referência quando comparada às outras.

Ao se observar a matriz de confusão (Tabela 18), nota-se que as classes Vegetação Rasteira e Vegetação Arbórea se misturaram, o que pode ter sido causado pela semelhança na resposta espectral destes alvos, entretanto, as classes que mais contribuíram para a redução das porcentagens dos coeficientes de concordância total foram Cobertura de Cerâmica e Solo Exposto, devido à semelhança espectral. A classe que obteve a pior separação das demais foi Cobertura Cimento Médio, que se misturou principalmente com a classe Asfalto.

As porcentagens de exatidão total para esta classificação atingiram valores de exatidão global, índice *Kappa* e índice *Tau* de 85,0%, 83,4% e 83,6%, respectivamente. *Kappa* com excelente resultado, segundo Landis e Koch (1977).

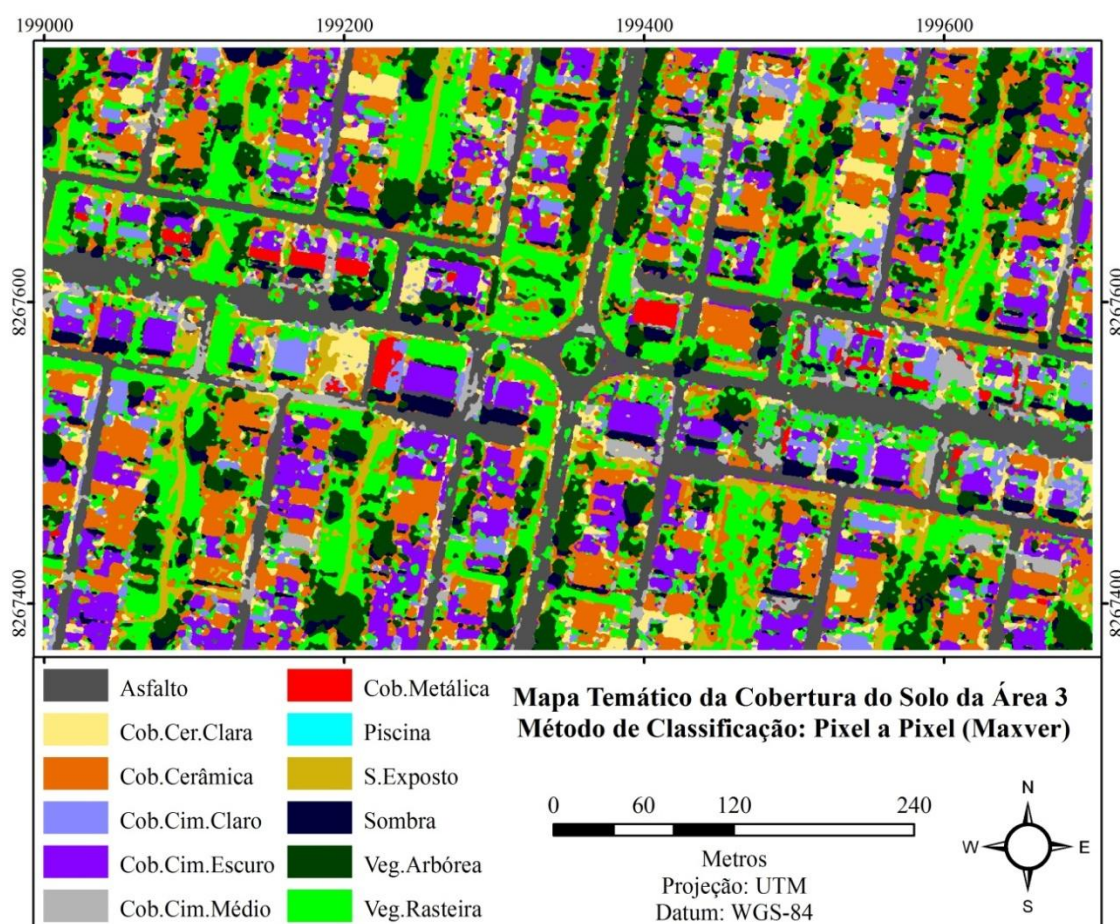


Figura 37 - Mapa temático resultante da classificação por *pixel* (Maxver) para a área-teste 3

Tabela 18 - Matriz de confusão da classificação por *pixel* (Maxver) para a área-teste 3

Referência (Verdade)	Classificação												
	Asfalto	Cobertura de Cerâmica Clara	Cobertura de Cerâmica	Cobertura de Cimento Claro	Cobertura de Cimento Escuro	Cobertura de Cimento Médio	Cobertura Metálica	Piscina	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	Total
Asfalto	55				1	1							57
Cobertura de Cerâmica Clara		28	2	5		4			5			1	45
Cobertura de Cerâmica			55						19	2			76
Cobertura de Cimento Claro		3		56		1	1						61
Cobertura de Cimento Escuro					72	3						2	77
Cobertura de Cimento Médio	8	1		1		15			1				26
Cobertura Metálica						1	17						18
Piscina	5		1				1	24				1	32
Solo Exposto			13						36			1	50
Sombra										64			64
Vegetação Arbórea										2	61	4	67
Vegetação Rasteira	2				1						2	55	60
Total	70	32	71	62	74	25	19	24	61	68	63	64	633

Os mapas temáticos resultantes das classificações por *pixel* SAM foram os que obtiveram as porcentagens dos coeficientes de concordância total mais baixos para as três áreas, isso pode ser explicado devido ao grande número de *pixels* isolados em outras classes (efeito “sal e pimenta”), causado por mistura espectral.

Na classificação da área-teste 1 (Figura 38), a classe que obteve a melhor separação das demais e mais contribuiu para o aumento das porcentagens dos coeficientes de concordância total foi Sombra, isso acontece devido ao seu grande número de amostras de referência classificado corretamente.

Quando se observa a matriz de confusão (Tabela 19), nota-se que a classe que mais contribuiu para a redução das porcentagens dos coeficientes de concordância total foi Solo Exposto, que se misturou principalmente com as classes Cobertura de Cerâmica Clara e Cobertura de Cerâmica devido à semelhança espectral. Outra mistura também causada por semelhança espectral foi da classe Vegetação Arbórea com Vegetação Rasteira.

As porcentagens de exatidão total para esta classificação atingiram valores de exatidão global, índice *Kappa* e índice *Tau* de 72,6%, 69,3% e 69,8%, respectivamente. *Kappa* com resultado muito bom, segundo classificação de Landis e Koch (1977).

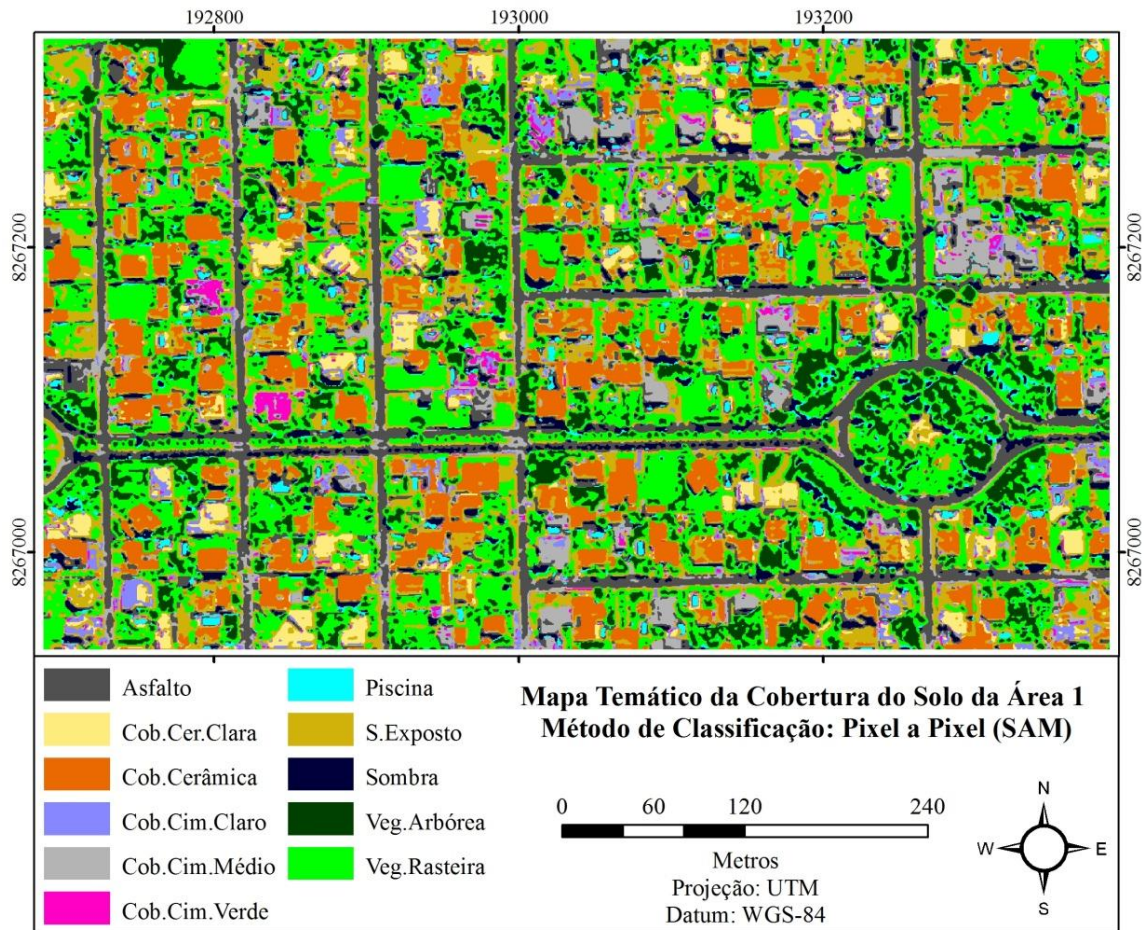


Figura 38 - Mapa temático resultante da classificação por *pixel* (SAM) para a área-teste 1

Tabela 19 - Matriz de confusão da classificação por *pixel* (SAM) para área-teste 1

Classificação \ Referência (Verdade)	Asfalto	Cobertura de Cerâmica Clara	Cobertura de Cerâmica	Cobertura de Cimento Claro	Cobertura de Cimento Médio	Cobertura de Cimento Verde	Piscina	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	Total
	Asfalto	60	1	1		9				10		
Cobertura de Cerâmica Clara	1	49	2	18				9				79
Cobertura de Cerâmica			67					9			1	77
Cobertura de Cimento Claro		3	1	14	1	3		3				25
Cobertura de Cimento Médio	13		2	12	32	2						61
Cobertura de Cimento Verde				4	1	12						17
Piscina							36		5			41
Solo Exposto	4	2	11	3		1		28			7	56
Sombra	1		1				1		46		1	50
Vegetação Arbórea										60	20	80
Vegetação Rasteira	2		1					2	4	15	91	115
Total	81	55	86	51	43	18	37	51	65	75	120	682

O mapa temático resultante da classificação por *pixel* SAM, para a área-teste 2 (Figura 39), também teve suas maiores misturas espectrais concentradas nas classes Solo Exposto e Cobertura de Cerâmica, o que contribuiu significativamente para a redução das porcentagens dos coeficientes de concordância total, onde mais uma vez a semelhança espectral foi determinante para que esse fato ocorresse.

Os melhores coeficientes de concordância total da classificação SAM para a área-teste 1 em relação à da área-teste 2 deram-se em virtude da melhor separação de classes como Asfalto, Vegetação Arbórea e Vegetação Rasteira que, conseqüentemente, contribuíram para o aumento das porcentagens.

Ao analisar a matriz de confusão (Tabela 20), nota-se que a classe que obteve a pior separação das demais foi Cobertura de Cimento Médio, que, devido à semelhança espectral, se misturou principalmente à classe Asfalto.

As porcentagens de exatidão total para esta classificação atingiram valores de exatidão global, índice *Kappa* e índice *Tau* de 73,5%, 70,2% e 70,6%, respectivamente. *Kappa* com resultado muito bom, segundo classificação de Landis e Koch (1977).

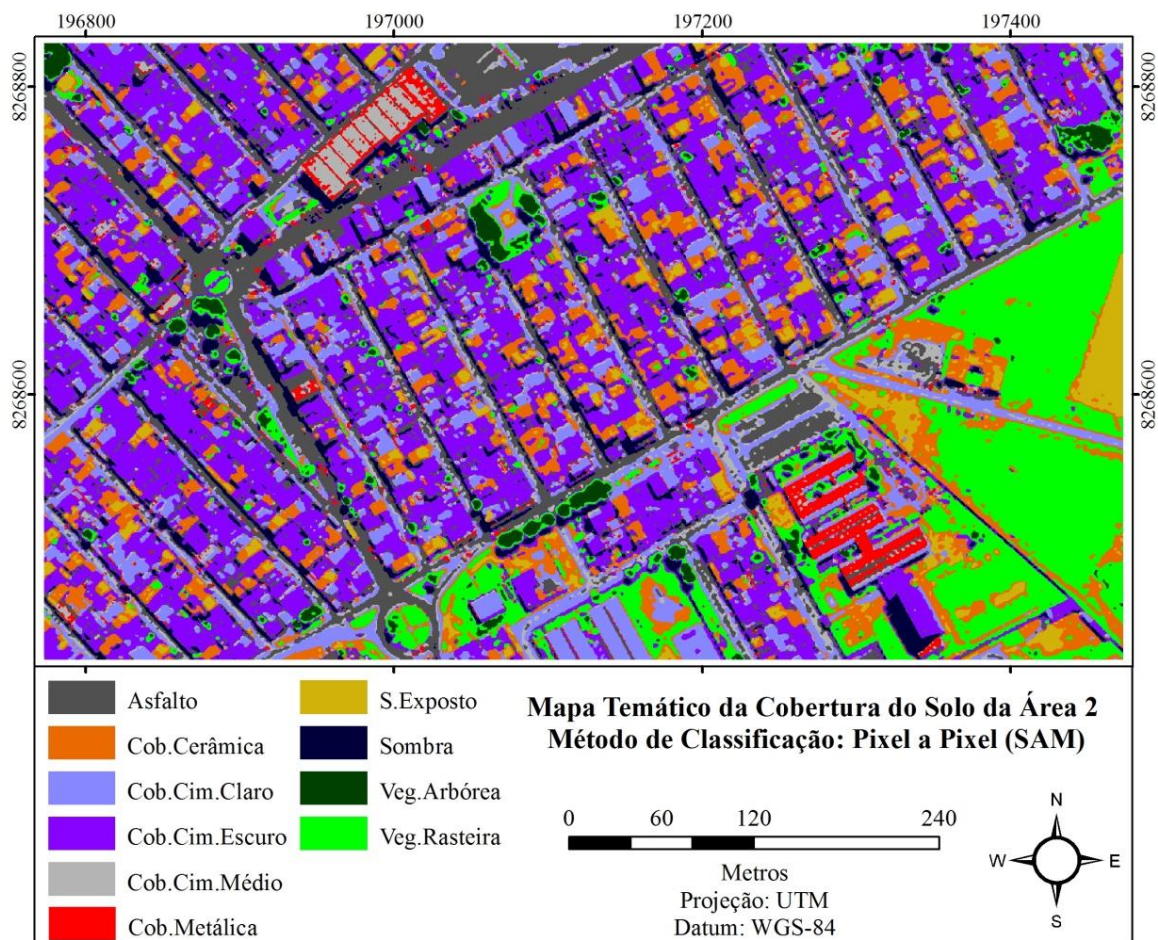


Figura 39 - Mapa temático resultante da classificação por *pixel* (SAM) para a área-teste 2

Tabela 20 - Matriz de confusão da classificação por *pixel* (SAM) para a área-teste 2

Referência (Verdade) Classificação	Asfalto	Cobertura de Cerâmica	Cobertura de Cimento Claro	Cobertura de Cimento Escuro	Cobertura de Cimento Médio	Cobertura Metálica	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	Total
Asfalto	50	1		3	3	2		2			61
Cobertura de Cerâmica	1	52					26			1	80
Cobertura de Cimento Claro	16	1	76		15	4	4			1	117
Cobertura de Cimento Escuro		2		93	3			1			99
Cobertura de Cimento Médio	21		4		8	6		1			40
Cobertura Metálica	1				2	13					16
Solo Exposto		38	2				33				73
Sombra				2			2	69			73
Vegetação Arbórea									38	3	41
Vegetação Rasteira		2	1				1		5	60	69
Total	89	96	83	98	31	25	66	73	43	65	669

Das três classificações SAM, a que obteve melhores porcentagens de coeficientes de concordância total foi a da área-teste 3 (Figura 40). As classes que mais contribuíram para o aumento destas porcentagens foram Asfalto, Cobertura de Cimento Claro, Cobertura Metálica e Sombra, por possuírem elevados números de amostras de referência classificadas corretamente, ou seja, boas separações das classes em relação às demais.

Ao analisar a matriz de confusão (Tabela 21), nota-se que a semelhança espectral mais uma vez fez as classes Cobertura de Cerâmica Clara, Cobertura de Cerâmica e Solo Exposto contribuírem significativamente para a redução dos coeficientes de concordância total, uma vez que detêm um considerável número de amostras de referência classificadas de forma errada.

Nesta área-teste, a quantidade de carros nas vias e estacionamentos proporcionou um efeito visual de *pixels* isolados (efeito “sal e pimenta”) da classe Cobertura Metálica na classe Asfalto, essa mistura pode ser explicada pelo mesmo material de origem dos dois alvos, entretanto, este fato somente é notado com análise visual no mapa temático, pois não se refletiu na matriz de confusão, uma vez que nenhuma amostra de referência da classe Asfalto caiu em um destes *pixels* isolados.

As porcentagens de exatidão total para esta classificação atingiram valores de exatidão global, índice *Kappa* e índice *Tau* de 75,0%, 73,5% e 72,8%, respectivamente. *Kappa* com resultado muito bom, segundo classificação de Landis e Koch (1977).

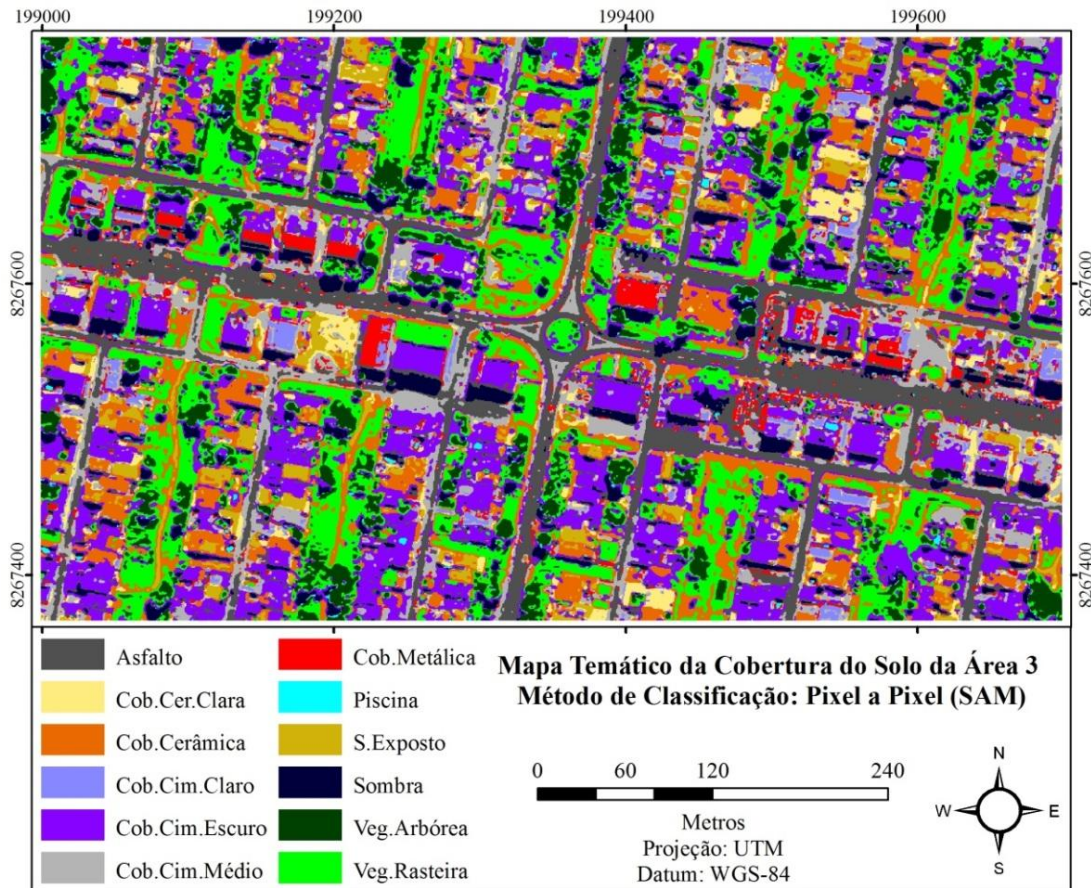


Figura 40 - Mapa temático resultante da classificação por *pixel* (SAM) para a área-teste 3

Tabela 21 - Matriz de confusão da classificação por *pixel* (SAM) para a área-teste 3

Referência (Verdade)													
	Asfalto	Cobertura de Cerâmica Clara	Cobertura de Cerâmica	Cobertura de Cimento Claro	Cobertura de Cimento Escuro	Cobertura de Cimento Médio	Cobertura Metálica	Piscina	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	Total
Asfalto	54				1								55
Cobertura de Cerâmica Clara		24	1	12		1			8				46
Cobertura de Cerâmica	1	2	45						25			3	76
Cobertura de Cimento Claro		4		40		1							45
Cobertura de Cimento Escuro	4		1		71	2		2	4		2	2	88
Cobertura de Cimento Médio	10		2	8	1	20	1		1			1	44
Cobertura Metálica				2	1		18						21
Piscina								18					18
Solo Exposto		2	22						24				48
Sombra	1							2		66		1	70
Vegetação Arbórea											45	7	52
Vegetação Rasteira					1				3		16	50	70
Total	70	32	71	62	75	24	19	22	65	66	63	64	633

5.4.1 Comparação dos coeficientes de concordância total entre as classificações

Analisando a Tabela 22, que demonstra os valores dos coeficientes de concordância Exatidão Global, *Kappa* e *Tau* calculados a partir das matrizes de confusão, nota-se que as porcentagens dos coeficientes de concordância mais altas foram as que compreendem as classificações baseadas em objeto, enquanto os valores mais baixos pertencem às classificações por *pixel* SAM (*Spectral Angle Mapper*). As figuras 41 a 43 apresentam os gráficos dos coeficientes de concordância total para as três classificações, evidenciando estas diferenças.

Ao analisar todos os percentuais dos coeficientes de concordância total de todas as classificações, percebe-se que nenhum valor ficou abaixo de 69%. Quando se avaliam os dados na categorização do *Kappa* de Landis e Koch (1977), a acurácia de todas as classificações se esquadram nas categorias “Muito Boa” e “Excelente”.

Tabela 22 - Coeficientes de concordância calculados para as três áreas-teste

	Área-teste 1				Área-teste 2				Área-teste 3			
	REG	OBJ	MAX	SAM	REG	OBJ	MAX	SAM	REG	OBJ	MAX	SAM
Exatidão Global	0,81	0,88	0,84	0,73	0,84	0,91	0,89	0,74	0,82	0,88	0,85	0,75
Índice <i>Kappa</i>	0,78	0,86	0,82	0,69	0,82	0,89	0,87	0,70	0,80	0,87	0,83	0,72
Índice <i>Tau</i>	0,79	0,86	0,82	0,70	0,83	0,90	0,87	0,71	0,81	0,87	0,84	0,73

Legenda: **REG:** classificação por região (Bhattacharyya), **OBJ:** classificação baseada em objetos, **MAX:** classificação por *pixel* (MAXVER) e **SAM:** classificação por *pixel* (*Spectral Angle Mapper*).

Os resultados mais elevados na classificação baseada em objetos deram-se em virtude da possibilidade de se utilizar, além da informação espectral, outras informações como forma, cor e inserção de regras de decisão que permitem cálculos entre bandas no processo de classificação, ampliando a possibilidade de isolamento dos alvos.

Os altos valores dos coeficientes de concordância total das classificações por *pixel* (Maxver), apesar de levarem em consideração apenas informações espectrais, as amostras de treinamento são utilizadas para estimar a forma da distribuição dos *pixels* contidos em cada classe no espaço de *n* bandas, como também a localização do centro de cada classe, buscando contemplar toda a heterogeneidade das imagens de forma representativa para todas as classes, entretanto, quando o controle de amostras de treinamento não é completamente efetivo, este tipo de classificação está sujeita a misturas espectrais.




Figura 41 - Coeficientes de concordância para a área-teste 1




Figura 42 - Coeficientes de concordância para a área-teste 2




Figura 43 - Coeficientes de concordância para a área-teste 3

5.4.2 Coeficientes de concordância por classe

Os valores dos coeficientes de concordância por classe deram suporte para a realização de uma análise da qualidade da separação dos alvos para cada classificação, discutidos a partir do item 5.3.3.1, para cada classe. Foram utilizados os coeficientes de concordância *Kappa* condicional (BISHOP *et al.*, 1975) e exatidão do usuário e do produtor (STORY & CONGALTON, 1986), extraídos da matriz de confusão (Tabelas 23 a 25).

Tabela 23 - Kappa condicional de cada classe das três áreas-teste

Classes	Área-teste 1				Área-teste 2				Área-teste 3			
	REG	OBJ	MAX	SAM	REG	OBJ	MAX	SAM	REG	OBJ	MAX	SAM
Asfalto	0,75	1	0,88	0,71	0,64	0,92	0,87	0,79	0,61	0,91	0,96	0,98
Cob. Cer.Clara	0,60	0,76	0,68	0,59	-	-	-	-	0,72	0,84	0,60	0,50
Cob. Cerâmica	0,82	0,82	0,86	0,85	0,74	0,82	0,67	0,59	0,89	0,88	0,69	0,54
Cob. Cim.Escuro	-	-	-	-	0,99	0,97	0,83	0,60	0,85	0,94	0,91	0,88
Cob. Cim.Claro	1	0,80	0,65	0,52	0,86	0,96	1	0,93	0,76	0,92	0,93	0,78
Cob. Cim.Médio	0,73	0,85	0,79	0,49	0,93	0,86	0,85	0,16	0,65	0,54	0,56	0,43
Cob. Cim.Verde	0,89	1	1	0,70	-	-	-	-	-	-	-	-
Cob. Metálica	-	-	-	-	0,78	1	1	0,81	0,82	0,74	0,94	0,85
Piscina	1	1	0,97	0,87	-	-	-	-	1	1	0,74	1
S. Exposto	0,44	0,83	0,59	0,46	0,88	0,78	0,95	0,39	0,86	0,86	0,69	0,44
Sombra	0,74	0,89	0,93	0,91	0,82	0,88	0,93	0,94	0,89	0,97	1	0,94
Veg. Arbórea	0,90	0,85	0,75	0,72	0,91	0,83	0,93	0,92	0,85	0,88	0,90	0,85
Veg. Rasteira	0,91	0,81	0,99	0,75	0,96	0,94	0,98	0,86	0,80	0,88	0,91	0,68

Tabela 24 - Exatidão do Usuário de cada classe das três áreas-teste

Classes	Área-teste 1				Área-teste 2				Área-teste 3			
	REG	OBJ	MAX	SAM	REG	OBJ	MAX	SAM	REG	OBJ	MAX	SAM
Asfalto	0,78	1	0,89	0,74	0,69	0,93	0,88	0,82	0,65	0,92	0,96	0,98
Cob. Cer.Clara	0,63	0,78	0,71	0,62	-	-	-	-	0,74	0,84	0,62	0,52
Cob. Cerâmica	0,84	0,84	0,88	0,87	0,77	0,84	0,71	0,65	0,90	0,89	0,72	0,59
Cob. Cim.Escuro	-	-	-	-	0,99	0,98	0,85	0,65	0,87	0,94	0,92	0,89
Cob. Cim.Claro	1	0,81	0,68	0,56	0,88	0,97	1	0,94	0,79	0,93	0,94	0,81
Cob. Cim.Médio	0,75	0,86	0,81	0,52	0,93	0,87	0,86	0,20	0,67	0,56	0,58	0,45
Cob. Cim.Verde	0,89	1	1	0,71	-	-	-	-	-	-	-	-
Cob. Metálica	-	-	-	-	0,79	1	1	0,81	0,83	0,75	0,94	0,86
Piscina	1	1	0,97	0,88	-	-	-	-	1	1	0,75	1
S. Exposto	0,49	0,85	0,62	0,50	0,89	0,80	0,95	0,45	0,87	0,87	0,72	0,50
Sombra	0,76	0,90	0,93	0,92	0,84	0,90	0,94	0,95	0,90	0,97	1	0,94
Veg. Arbórea	0,91	0,86	0,77	0,75	0,92	0,84	0,93	0,93	0,87	0,89	0,91	0,87
Veg. Rasteira	0,92	0,84	0,99	0,79	0,96	0,95	0,98	0,87	0,82	0,90	0,92	0,71

Tabela 25 - Exatidão do Produtor de cada classe das três áreas-teste

Classes	Área-teste 1				Área-teste 2				Área-teste 3			
	REG	OBJ	MAX	SAM	REG	OBJ	MAX	SAM	REG	OBJ	MAX	SAM
Asfalto	0,79	0,95	0,83	0,74	0,89	1	0,93	0,56	0,74	0,99	0,79	0,77
Cob. Cer.Clara	0,46	0,64	0,79	0,89	-	-	-	-	0,81	0,84	0,88	0,75
Cob. Cerâmica	0,95	0,94	0,96	0,78	0,98	0,89	0,98	0,54	0,89	0,92	0,77	0,63
Cob. Cim.Escuro	-	-	-	-	0,93	0,99	1	0,92	0,83	0,80	0,90	0,65
Cob. Cim.Claro	0,67	0,84	0,78	0,27	0,85	0,94	0,90	0,95	0,74	0,92	0,97	0,95
Cob. Cim.Médio	0,77	0,90	0,69	0,74	0,48	0,87	0,89	0,26	0,64	0,88	0,60	0,83
Cob. Cim.Verde	0,89	0,79	0,79	0,67	-	-	-	-	-	-	-	-
Cob. Metálica	-	-	-	-	0,88	0,76	0,76	0,52	0,95	0,95	0,89	0,95
Piscina	0,95	0,95	1	0,97	-	-	-	-	0,95	0,64	1	0,82
S. Exposto	0,71	0,65	0,65	0,55	0,58	0,73	0,55	0,50	0,77	0,79	0,59	0,37
Sombra	0,89	0,94	0,85	0,71	1	0,96	0,88	0,95	0,91	1	0,94	1
Veg. Arbórea	0,80	0,93	1	0,80	0,77	0,98	0,98	0,88	0,81	0,90	0,97	0,71
Veg. Rasteira	0,89	0,91	0,78	0,76	0,78	0,80	0,89	0,92	0,87	0,81	0,86	0,78

Analisando as Tabelas 23, 24 e 25, nota-se que as classes que alcançaram coeficientes de concordância total mais elevados estão concentradas nas classificações baseadas em objetos e por *pixel* (Maxver), representando uma melhor separação das classes. Cada uma das treze classes pertencentes às três áreas-teste foi analisada com o objetivo de explicar os resultados obtidos para cada uma.

5.4.2.1 Asfalto

Os melhores coeficientes de concordância por classe para a classe Asfalto foram obtidos pela classificação baseada em objeto (Figura 46), em virtude da utilização de um arquivo *shapefile*, que serviu como máscara para as classificações baseadas em objeto, o que resultou em um *Kappa* condicional e exatidão do usuário máximos, ou seja, não houve erros de comissão. Em nenhum momento, nesta classe, o classificador classificou outros alvos erroneamente como asfalto, já o contrário, ou seja, erros de comissão, aconteceram em menor proporção quando o classificador deixou de classificar alguns alvos desta classe. Estes alvos acabaram incorporando-se em outras classes, geralmente naquelas com algum tipo de semelhança com a Asfalto. Neste caso, o classificador incorporou os alvos omitidos da classe Asfalto nas classes Sombra e Vegetação Arbórea.

Analisando os gráficos da figura 44, que demonstram a média e desvio-padrão dos três coeficientes de concordância por classe, percebe-se que nas classificações que utilizam somente informações espectrais como forma de separação, a classe Asfalto sofreu maior

mistura espectral. A classificação que obteve as médias dos coeficientes de concordância mais baixas foi por região (Bhattacharyya), onde aconteceram tanto erros de comissão como de omissão, refletindo diretamente em seus coeficientes de concordância referentes à exatidão do usuário e produtor. Isso ocorreu nesta classificação porque a classe Asfalto misturou-se com a Cobertura de Cimento Escuro, o que pode ser explicado pela semelhança espectral dos dois alvos (Figura 46).

Analisando o gráfico “b” da figura 45, que representa o desvio-padrão dos três coeficientes de concordância para cada classificação, nota-se que a classificação baseada em objetos obteve baixos percentuais, além de uma regularidade nas três áreas-teste, mostrando um equilíbrio dos três coeficientes de concordância. Nas outras classificações, os valores de desvio-padrão não mantiveram a mesma regularidade devido aos diferentes valores de coeficientes de concordância em uma mesma classificação, além de diferentes resultados para cada área-teste.




Figura 44 - Coeficientes de concordância para a classe Asfalto




Figura 45 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Asfalto

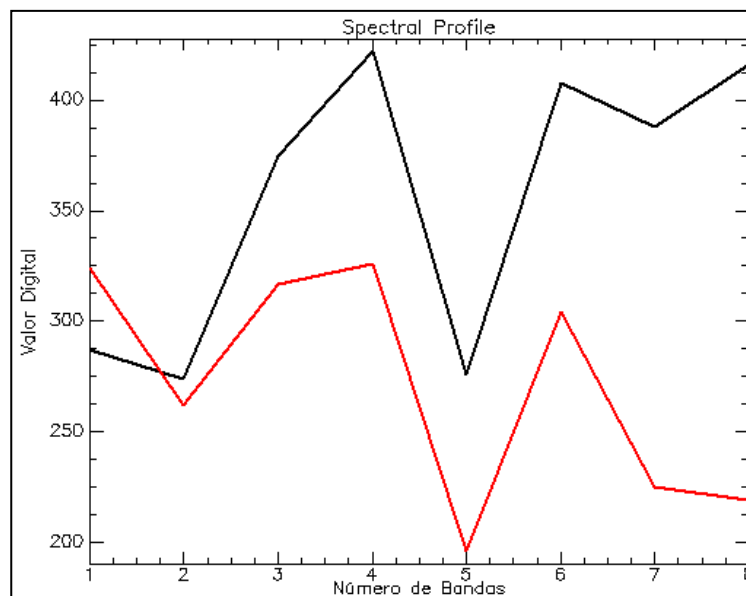


Figura 46 - Espectro dos alvos: Asfalto (linha em preto) e Cobertura de Cimento Escuro (linha em vermelho)

5.4.2.2 Cobertura de Cerâmica Clara

A classe Cobertura de Cerâmica Clara está presente somente nas áreas-teste 1 e 3. A melhor separação desta classe ocorreu na classificação baseada em objeto. Quando se observa o gráfico da figura 47, a separação não fica muito evidente devido à oscilação dos coeficientes de concordância de todas as classes, entretanto, quando se observa o gráfico “a” na figura 48, que apresenta as médias dos três coeficientes de concordância, nota-se que os valores mais altos encontram-se nas classificações baseadas em objeto, devido a utilização de outros parâmetros na classificação, como forma, cor e a exploração das bandas do sensor Worldview II, que possibilitou uma exploração desta classe, particularizando-a.

O índice mais baixo encontra-se na classificação por região (Bhattacharyya) na área-teste 1, isso ocorreu devido à classes como Cobertura de Cerâmica, Solo Exposto e Cobertura Cimento Claro se misturarem com a classe Cobertura de Cerâmica Clara, em virtude da semelhança espectral. Esta mistura em todas as classificações da Cobertura de Cerâmica Clara com a classe Cobertura de Cerâmica está associada ao igual material de origem, pois a única diferença destes alvos está em um detalhe de fabricação, onde a telha de cerâmica clara é menos cozida, além de ser fabricada com argilas com menor teor de óxido de ferro que a telha de cerâmica e, por isso, sua coloração é mais clara. Ao se observar a figura 49, percebe-se que o espectro da telha de cerâmica clara (linha preta) comporta-se da mesma forma que o espectro da telha de cerâmica (linha vermelha), tendo uma diferença apenas no albedo, ou seja, os

valores do espectro da telha de cerâmica clara são mais altos, e, conseqüentemente, mais claros.

Outro alvo que se misturou bastante com a classe Cobertura Cerâmica Clara foi a classe Solo Exposto, o que também pode ser explicado pela semelhança espectral, devido a semelhança do material de origem. Na figura 49, percebe-se que o espectro da telha de cerâmica clara, representado pela linha preta, tem um comportamento espectral próximo ao espectro do solo exposto, representado pela linha azul.

Analisando o gráfico “b” da figura 48, que representa o desvio-padrão dos três coeficientes de concordância, nota-se que a classificação baseada em objetos na área-teste 3 obteve um valor de desvio-padrão bem próximo de zero, o que significa uma regularidade entre erros de omissão e comissão, fazendo com que os três valores de coeficientes de concordância fiquem parecidos. Já a classificação por *pixel* (SAM) apresentou o maior valor de desvio-padrão, significando uma irregularidade entre os valores dos coeficientes de concordância, isso ocorreu em virtude do elevado valor do coeficiente de concordância referente à Exatidão do produtor de cada área-teste em relação aos outros valores de coeficientes de concordância da mesma classificação. Neste caso, estes valores foram elevados em virtude do baixo valor de erros de omissão, ou seja, houve poucas amostras desta classe específica que foram classificadas como outras.




Figura 47 - Coeficientes de concordância para a classe Cobertura de Cerâmica Clara




Figura 48 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Cobertura Cerâmica Clara




Figura 49 - Espectro dos alvos: Cobertura Cerâmica Clara (linha em preto), Cobertura Cerâmica (linha em vermelho) e Solo Exposto (linha em azul)

5.4.2.3 Cobertura Cerâmica

A classe Cobertura Cerâmica está presente em todas as áreas-teste e sua melhor separação foi na classificação por *pixel* (Maxver), já o pior desempenho foi obtido pela classificação SAM, apresentando valores menores que 70% (Figura 50).

Observando-se o gráfico “a” da figura 51, que apresenta as médias dos três coeficientes de concordância, observa-se que quase todas as classificações alcançaram médias dos coeficientes de concordância acima de 80%, configurando uma boa separação dos alvos, apesar de sua semelhança espectral com o alvo Solo Exposto. Já no gráfico “b” da figura 51, percebe-se que esta regularidade dos coeficientes de concordância é menos expressiva nas classificações por região (Bhattacharyya) e por *pixel* (Maxver) da área-teste 2, uma vez que tiveram poucos erros de omissão, ou seja, poucas amostras desta classe foram classificadas

como outras, e altos valores de erros de comissão, ou seja, amostras de outras classes, neste caso Solo Exposto, classificadas como Cobertura de Cerâmica.

A classificação por *pixel* (SAM) na área-teste 2 obteve as piores porcentagens dos coeficientes de concordância, em virtude da mistura espectral com a classe Solo Exposto, o que causou altos valores de erros de comissão e omissão resultando em baixos coeficientes de concordância.

Apesar da classificação por objeto não ter tido as melhores médias dos coeficientes de concordância, esta foi a que obteve a melhor regularidade de desvio-padrão, mantendo os valores das três áreas-teste mais baixos em relação aos demais.




Figura 50 - Coeficientes de concordância para a classe Cobertura Cerâmica




Figura 51 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Cobertura de Cerâmica

5.4.2.4 Cobertura de Cimento Claro

A melhor separação da classe Cobertura de Cimento Claro foi alcançada pela classificação baseada em objetos na área-teste 2 (Figura 52). Quando se observa o gráfico “a” da figura 53, que apresenta as médias dos três coeficientes de concordância, percebe-se que os coeficientes de concordância da classificação por região (Bhattacharyya) mantiveram-se acima de 85%, entretanto, analisando o gráfico “b” da figura 53, percebe-se que esta regularidade não é tão expressiva, já o desvio-padrão da área-teste 1 está bem elevado. Isso ocorreu devido aos erros de omissão, já que parte dos alvos pertencentes à classe Cobertura de Cimento Claro foram classificados como Cobertura de Cerâmica Clara, resultando em uma baixa Exatidão do Produtor.

Na maioria das classificações, a classe que causou maior confusão com a classe Cobertura de Cimento Claro foi a Cobertura de Cerâmica Clara. Essa mistura pode ser explicada pela semelhança espectral desses alvos. Na figura 54, percebe-se que os espectros dos dois alvos são muito semelhantes, a linha preta representa o espectro dos alvos da classe Cobertura de Cimento Claro, enquanto a linha vermelha representa o espectro dos alvos Cobertura de Cerâmica Clara.




Figura 52 - Coeficientes de concordância para a classe Cobertura de Cimento Claro

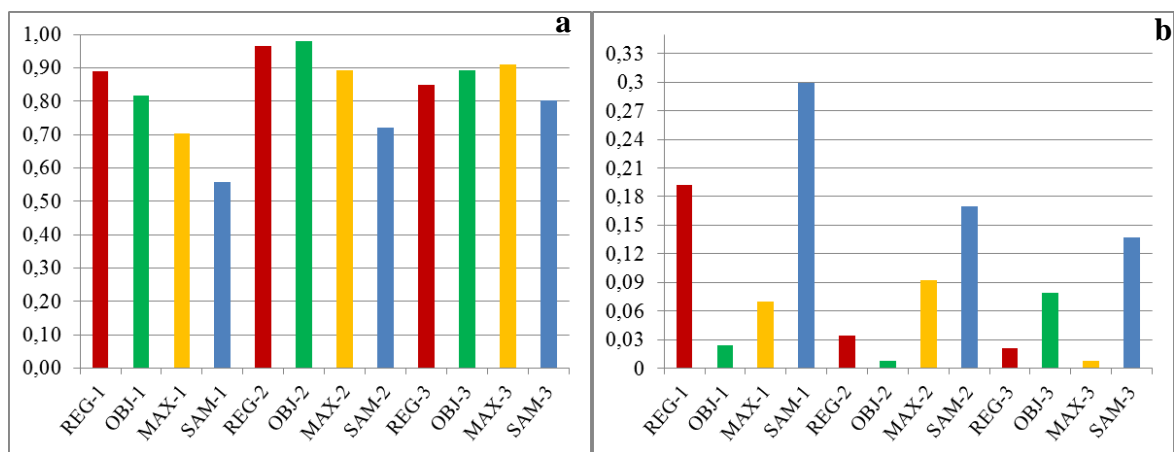


Figura 53 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Cobertura de Cimento Claro




Figura 54 - Espectro dos alvos: Cobertura de Cimento Claro (linha em preto) e Cobertura de Cerâmica Clara (linha em vermelho)

5.4.2.5 Cobertura de Cimento Escuro

A classe Cobertura de Cimento Escuro está presente somente nas áreas-teste 2 e 3. A melhor separação desta classe foi obtida na classificação por *pixel* (Maxver), que atingiu um *Kappa* condicional e exatidão do usuário máximos na área-teste 2, o que significa que houve uma excelente separação desta classe em relação às demais, sem erros de comissão (Figura 55), mesmo com o valor da Exatidão do Produtor mais baixo que de outras classificações. Este fato foi responsável pelo índice de desvio-padrão mais elevado no gráfico “b” da figura 56.

De modo geral, observando o gráfico “a” da figura 55, nota-se que todas as classificações obtiveram coeficientes de concordância elevados, com valores acima de 76%. Os valores mais baixos foram causados em função da mistura com a classe Asfalto.




Figura 55 - Coeficientes de concordância para a classe Cobertura de Cimento Escuro




Figura 56 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Cobertura de Cimento Escuro

5.4.2.6 Cobertura de Cimento Médio

A classe Cobertura de Cimento Médio está presente em todas as áreas-teste. Os maiores valores de coeficientes de concordância para a classe Cobertura de Cimento Médio foram obtidos nas classificações baseadas em objeto e por *pixel* Maxver (Figura 57), ambas alcançaram médias dos coeficientes de concordância acima de 87% (Figura 58, gráfico “a”).

O pior resultado foi a classificação por *pixel* SAM, que obteve uma média de valores de coeficientes de concordância de 21%. Isso ocorreu devido a uma grande mistura desta classe, nesta classificação, com a classe Cobertura de Cerâmica Clara.

O maior desvio-padrão dos coeficientes de concordância (Figura 58, gráfico “b”) aconteceu na classificação por região (Bhattacharyya) na área-teste 2, isso ocorreu devido aos

erros de omissão, já que parte dos alvos pertencentes à classe Cobertura de Cimento Médio foram classificados como Asfalto, resultando em um baixo índice de Exatidão do Produtor. Esse fato pode ser explicado pela sua semelhança espectral com a classe Asfalto (Figura 59). Na figura 61 é apresentada a semelhança dos espectros destas classes, a linha preta representa o espectro da classe Cobertura de Cimento Médio e a linha vermelha representa a classe Asfalto.

De forma geral, percebe-se que nas classificações que utilizam somente informações espectrais como forma de separação, a classe Cobertura de Cimento Médio sofreu maior mistura espectral e que as maiores misturas ocorreram com a classe Asfalto.




Figura 57 - Coeficientes de concordância para a classe Cobertura de Cimento Médio




Figura 58 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Cobertura de Cimento Médio




Figura 59 - Espectro dos alvos: Cobertura de Cimento Médio (linha em preto) e Asfalto (linha em vermelho).

5.4.2.7 Cobertura de Cimento com Pigmentação Verde

A classe Cobertura de Cimento Verde está presente apenas na área-teste teste 1. Por ter uma resposta de cobertura diferente das demais, já que representa um alvo constituído por telhas de cimento de cor esverdeada, esta classe apresentou uma boa separação das demais nas quatro classificações. Observando-se a figura 60, os coeficientes de concordância das classificações baseadas em objetos e Maxver atingiram um *Kappa* condicional e exatidão do usuário máximos, o que significa que houve uma excelente separação dela em relação às demais, ou seja, não houve erros de comissão. Em nenhum momento, nesta classe, os classificadores classificaram outros alvos erroneamente como Cobertura de Cimento Verde, já erros de omissão aconteceram em menor proporção, quando o classificador deixou de classificar alguns dos alvos desta classe e estes alvos acabaram incorporando-se em outras, neste caso, a maioria incorporou-se na classe Cobertura de Cimento Médio, já que são semelhantes devido ao material de origem.

Analisando o gráfico “a” da figura 61, que apresenta as médias dos três coeficientes de concordância por classe, percebe-se que, das quatro classificações, a que obteve o pior índice foi a classificação por *pixel* SAM, que apresentou mistura espectral, principalmente, com a classe Cobertura de Cimento Médio, que pode ser explicada pelo material de origem, pois os dois alvos têm cimento em sua composição.

No gráfico “b” da figura 61 percebe-se que a classificação baseada em objetos e por *pixel* (Maxver) possui valores de desvio-padrão dos coeficientes de concordância mais elevados, nos dois casos ocorreram poucos erros de omissão, ou seja, poucas amostras da

classe Cobertura de Cimento Verde foram classificadas como outras, e muitos erros de comissão, ou seja, amostras de outras classes, neste caso, Cobertura de Cimento Médio, foram classificadas como Cobertura de Cimento Verde.

Ainda analisando o gráfico “b” da figura 61, nota-se que a classificação que obteve, além de altos valores de coeficiente de concordância, maior regularidade entre os três coeficientes foi a classificação por região (Bhattacharyya), com um valor de desvio-padrão bem próximo de zero, mostrando um equilíbrio nos erros de omissão e comissão que refletiu nos valores semelhantes calculados para os três coeficientes de concordância. Estes fatos ocorreram devido a pouca mistura desta classe com as demais.




Figura 60 - Coeficientes de concordância para a classe Cobertura Cimento Verde




Figura 61 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Cobertura de Cimento Verde

5.4.2.8 Cobertura Metálica

A classe Cobertura Metálica está presente nas áreas-teste 2 e 3. Observando-se a figura 62, nota-se que os coeficientes de concordância das classificações baseadas em objetos e por *pixel* (Maxver) atingiram um *Kappa* condicional e exatidão do usuário máximos, o que significa que houve uma excelente separação da classe em relação às demais, com destaque para a classificação Maxver, que obteve um valor de média dos coeficientes acima de 93% e pouca variação entre os coeficientes de concordância (gráfico “b” da Figura 63).

Nos valores das médias dos coeficientes de concordância no gráfico “a” da figura 63, observa-se que os valores mais baixos foram da classificação SAM, que podem ser explicados pela mistura com a classe Cobertura Cimento Médio, já que suas respostas espectrais são semelhantes (Figura 64).




Figura 62 - Coeficientes de concordância para a classe Cobertura Metálica




Figura 63 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Cobertura Metálica




Figura 64 - Espectro dos alvos: Cobertura de Cimento Médio (linha em preto) e Cobertura Metálica (linha em vermelho)

5.4.2.9 Piscina

A classe Piscina está presente apenas nas áreas 1 e 3. Observando-se a figura 65, os coeficientes de concordância das classificações baseadas em objetos, Maxver e por região (Bhattacharyya), atingiram um *Kappa* condicional e exatidão do usuário máximos, o que significa que houve uma excelente separação dela em relação às demais classes. Neste caso, não houve erros de comissão em nenhum momento. Nesta classe, o classificador classificou outros alvos de forma errada como piscina, já o contrário, ou seja, erros de omissão aconteceram em pequena escala, já que o classificador não classificou alguns alvos como deveria classificar, assim, esses alvos acabaram incorporando-se em outras classes.

Observando a gráfico “a” da figura 66, que apresenta a média dos coeficientes de concordância, nota-se que a classificação que manteve os valores mais altos nas duas áreas-teste foi a por região (Bhattacharyya) e esta média corresponde à realidade dos três coeficientes de concordância, já que no gráfico “b” da figura 66 notam-se baixos valores de desvio-padrão dos coeficientes de concordância.

De modo geral, a classe Piscina em todas as classificações alcançou valores satisfatórios com média de coeficientes de concordância acima de 83%.




Figura 65 - Coeficientes de concordância para a classe Piscina




Figura 66 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Piscina

5.4.2.10 Solo Exposto

Na classe Solo Exposto, em todas as classificações aconteceram erros de omissão e comissão, sendo que os erros de omissão de uma classe contribuem para os erros de comissão de outras, pois uma vez que um alvo não é classificado em uma determinada classe ele acaba incorporando-se em outra e transformando-se em erros de comissão. As classes que mais se confundiram com a classe Solo Exposto foram Cobertura de Cerâmica e Cobertura de Cerâmica Clara. Esta mistura ocorreu em virtude da semelhança espectral destas classes.

Observando a figura 67, que apresenta os coeficientes de concordância, nota-se que a classificação com valores mais altos foi a baseada em objetos da área-teste 3. Isso pode ser melhor visualizado no gráfico “a” da figura 68, que apresenta a média dos coeficientes de concordância, onde o valor para classificação baseada em objetos desta área-teste está acima de

84%. Este valor reflete a realidade, pois o desvio-padrão dos coeficientes de concordância, apresentado no gráfico “b” da figura 68, reflete uma baixa variação dos valores.




Figura 67 - Coeficientes de concordância para a classe Solo Exposto




Figura 68 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Solo Exposto

5.4.2.11 Sombra

A classe Sombra está presente em todas as áreas-teste. Os melhores coeficientes de concordância por classe foram obtidos pelas classificações baseadas em objetos e por *pixel* (Maxver) para a área-teste 3 (Figura 69), obtendo uma boa separação das demais classes. Quando se analisa a média dos coeficientes de variação no gráfico “a” da figura 70, percebe-se que ambas as classificações alcançaram coeficientes de concordância superiores a 98%, entretanto, ao analisar o gráfico “b” da figura 70 figura nota-se que o desvio-padrão da classificação por *pixel* (Maxver) obteve um índice menor.

Como a classe Sombra representa áreas mais escuras da imagem, ou seja, áreas com médias de valores espectrais mais baixas, sua identificação foi feita basicamente pela ausência de brilho das bandas da imagem, assim, as classes que apresentaram confusão em relação a ela foram aquelas com menores valores de brilho, como a classe Asfalto, Cobertura de Cimento Médio, Cobertura de Cerâmica e Vegetação Arbórea.




Figura 69 - Coeficientes de concordância para a classe Sombra




Figura 70 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Sombra

5.4.2.12 Vegetação Arbórea

Os melhores coeficientes de concordância por classe para Vegetação Arbórea foram obtidos pelas classificações por *pixel* (Maxver) (Figura 71), atingindo índice de média de valores de concordância acima de 95% para a área-teste 2 (gráfico “a” da Figura 72), e esta

média corresponde à realidade dos três valores de coeficientes de concordância, já que no gráfico “b” da figura 72 nota-se baixo valor de desvio-padrão dos coeficientes de concordância para a área-teste.

A semelhança espectral das classes Vegetação Arbórea e Vegetação Rasteira causou certa mistura entre estes alvos em todas as classificações. Esta mistura ocorreu em maior proporção na classificação por *pixel* (SAM), principalmente no caso da Vegetação Arbórea, o que foi refletido diretamente no valor de seus coeficientes de concordância, causando os valores mais baixos de todas as classificações.

Outro fato que chamou a atenção foi a mistura espectral da Vegetação Arbórea com a classe Sombra, que pode ser explicada pelo fato de algumas árvores apresentarem uma coloração escura. A semelhança espectral de alvos com pouco brilho está no baixo albedo do espectro, fazendo com que, eventualmente, alvos com coloração mais escura se confundam com sombra.

De forma geral, todas as classificações apresentaram uma boa separação da classe Vegetação Arbórea das demais classes, pois todas as classificações atingiram valores de coeficientes de concordância acima de 76%.




Figura 71 - Coeficientes de concordância para a classe Vegetação Arbórea




Figura 72 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Vegetação Arbórea

5.4.2.13 Vegetação Rasteira

Os coeficientes de concordância por classe para Vegetação Rasteira que obtiveram melhores resultados foram obtidos pela classificação por *pixel* (Maxver) (Figura 73), atingindo média de valores de concordância acima de 95% na área-teste 2, configurando uma boa separação desta classe em relação às demais (gráfico “a” da Figura 74), e esta média corresponde à realidade dos três coeficientes de concordância, já que no gráfico “b” da mesma figura nota-se um baixo valor de desvio-padrão dos coeficientes de concordância para a área-teste.

Em todas as classificações, a classe Vegetação Rasteira apresentou mistura com a classe Solo Exposto, o que pode ter ocorrido devido a algumas áreas apresentarem vegetação rasteira bem rala ou seca, em virtude da época do ano, expondo o solo e dificultando a separação espectral das classes.




Figura 73 - Coeficientes de concordância para a classe Vegetação Rasteira

As piores porcentagens dos coeficientes de concordância foram obtidas pela classificação por *pixel* (SAM), e podem ser explicadas devido à semelhança espectral das classes Vegetação Arbórea e Vegetação Rasteira (Figura 75), que causou muita mistura entre estes alvos nesta classificação.




Figura 74 - Média (a) e desvio-padrão (b) dos coeficientes de concordância para a classe Vegetação Rasteira

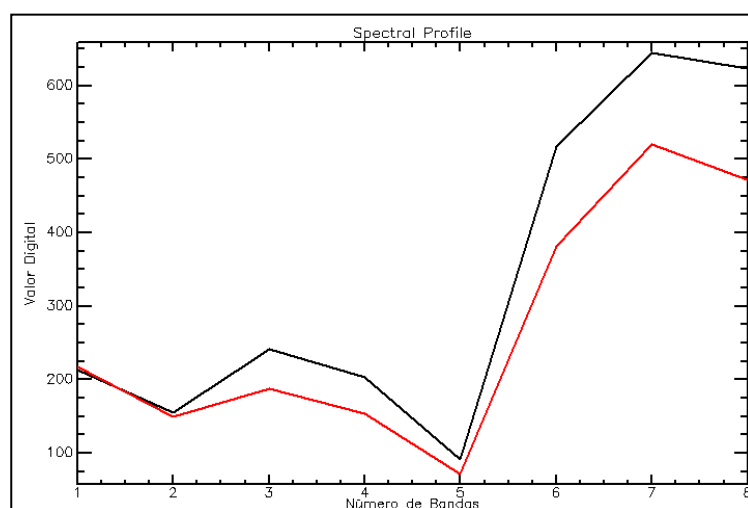


Figura 75 - Espectro dos alvos: Vegetação Rasteira (linha em preto) e Vegetação Arbórea (linha em vermelho)

6 CONCLUSÕES E RECOMENDAÇÕES

Após a aplicação da metodologia definida e a realização das análises e discussões dos resultados alcançados, pode-se concluir que:

- a) A classificação por região com o método Bhattacharyya demonstrou-se um eficiente método para classificação de áreas urbanas, obtendo coeficientes de concordância acima de 78%. No entanto, a classificação encontrou dificuldades na separação de alvos com muita semelhança espectral, como é o exemplo de coberturas cerâmicas e solo exposto e na escolha dos limiares de área e similaridade, fatores determinantes para a classificação por região. Assim, de uma forma geral, pode-se afirmar que o método é limitado quando utilizado para separação de alvos urbanos com imagens do WorldView II.
- b) Das quatro abordagens analisadas neste trabalho as classificações baseadas em objeto foi a mais eficiente para o mapeamento de áreas urbanas, uma vez que alcançou os mais altos coeficientes de concordância total permanecendo com valores acima de 86%, representando excelentes resultados segundo a classificação Landis e Koch (1977), mostrando-se excelente abordagem para a redução do problema da mistura espectral, encontrado em classificadores tradicionais, principalmente quando se trabalha com imagens do WorldView II, pois seu número de bandas permite uma melhor separação das classes, auxiliando na redução dos efeitos decorrentes da mistura espectral.
- c) Apesar dos coeficientes de concordância total para a classificação SAM permanecerem acima de 69%, enquadrando-se, segundo classificação Landis e Koch (1977), ela não apresentou bons resultados na separação das classes quando comparada com as demais, tanto nas matrizes de confusão quanto na avaliação visual dos mapas temáticos, entretanto vários estudos (Yuhas *et al.*, 1992; Conel *et al.*, 1992; Moreira & Galvão, 2009; Demattê *et al.*, 1992) atestam sua eficiência para tratamento de dados com imagens hiperespectrais.
- d) Na classificação *Maximum Likelihood* (Maxver) apesar do grande número pixels isolados em outras classes (efeito “sal e pimenta”) e misturas em alvos que

apresentam semelhança espectral, ela se mostrou eficiente para o mapeamento de áreas urbanas, pois seus coeficientes de concordância total permaneceram acima de 82%, excelente classificação segundo a classificação Landis e Koch (1977), assim, este classificador atende muito bem a separação de feições que não apresentem semelhança espectral. Outro fator que ficou evidente nesta abordagem foi que o critério na coleta de amostras de treinamento é um fator determinante para qualidade da classificação, pois se as amostras são bem representativas e buscam contemplar toda heterogeneidade da imagem o classificador é treinado com maior eficiência.

- e) Quanto à separação das classes, conclui-se que os melhores resultados para Asfalto, Cobertura Cerâmica Clara, Cobertura Cimento Claro, Cobertura Metálica, Piscina, Solo Exposto e Sombra pertenceram a abordagem baseada em objetos, enquanto que os melhores resultados para Cobertura Cerâmica, Cobertura Cimento Escuro, Vegetação Arbórea e Vegetação Rasteira pertenceram a abordagem por pixel (Maxver), já as classes Cobertura de Cimento Médio, Cobertura Cimento Verde obtiveram resultados idênticos para as duas abordagens.
- f) Quanto ao uso do sistema InterIMAGE, conclui-se que o aplicativo mostrou-se uma boa alternativa para análises de imagens baseadas em objeto, pois é uma iniciativa de desenvolvimento *open source*, além de permitir que o modelo de conhecimento usado na interpretação possa ser depurado e melhorado, através da introdução de mais conhecimento acerca das classes de interesse. Além disso, uma vez que o conhecimento está explicitamente representado, o modelo pode ser disseminado, analisado e criticado por uma comunidade de usuários.
- g) Para comparação de abordagens subjetivas, ou seja, que têm alguma interferência do profissional (seleção de amostras de treinamento, definição de área e similaridade, construção de regras de decisão), se faz necessária uma rigorosa análise estatística (construção e análises de matrizes de confissão e cálculos de variados coeficientes de variação) para que tudo deixe de ser subjetivo e passe a demonstrar que os dados são consistentes.
- h) Finalmente, pode-se concluir que a utilização de um software baseado em objetos apresenta uma série de vantagens em relação aos classificadores tradicionais,

contemplando: classificação em diferentes níveis de escalas na mesma cena, relações com objetos vizinhos, exploração de parâmetros de forma, cor e textura, área, comprimento, largura, direção, inserção de informações auxiliares como dados vetoriais, e a possibilidade da criação de regras de decisão integrando todos estes atributos.

6.1 Recomendações e sugestões

A partir do desenvolvimento e aplicações das ferramentas disponíveis no software InterIMAGE, sugerimos:

- a) Melhoria do processo de realização de análises em grandes áreas, pois o software apresenta uma limitação quanto ao número de segmentos gerados, obrigando uma redução no tamanho do recorte da imagem estudada.
- b) Desenvolvimento de uma ferramenta dinâmica de fatiamento de histograma no recurso *Analysis Manager* resultaria em um ganho de tempo na construção de regras de decisão.
- c) Inserção de ferramenta para verificação de acurácia.
- d) Desenvolvimento de ferramentas para aprendizado de máquina e mineração de dados, a fim de se reduzir tempo na construção manual de regras de decisão. Uma alternativa de ferramenta para este recurso é o *software* WEKA, pois além de ser uma iniciativa de desenvolvimento *open source* possui ferramentas para aprendizado de máquina e mineração de dados e um conjunto de regras de classificação, regressão, associação e algoritmos de agrupamento.

6.2 Propostas para trabalhos futuros

- a) Aplicar regras de decisão para análises multitemporais, aplicando técnicas de inferência espacial no intuito de indicar crescimento urbano.

- b) Comparar classificações baseadas em objeto feitas neste trabalho com outras classificações baseadas em objeto feitas com regras geradas a partir de mineração de dados, uma vez que neste trabalho as regras foram construídas de forma manual.

- c) Desenvolvimento de aplicação baseada em objetos e integração com análise fractal objetivando análise ambientais.

7 REFERÊNCIAS BIBLIOGRÁFICAS

- AL-AHMADI, F. S.; HAMES, A. S. Comparison of four classification methods to extract land use and land cover from raw satellite images for some remote arid areas. *Journal of King Abdulaziz University - Earth Sciences, Kingdom of Saudi Arabia*, v. 20(1), p. 167-191, 2009.
- ALMEIDA, W. S.; SOUZA, N. M. Avaliação das informações espectrais dos dados WorldView 2/Digital Globe para classificação temática de uso e cobertura do solo. In: *Anais XV Simpósio Brasileiro de Sensoriamento Remoto (SBSR)*. Curitiba: INPE, p. 1043-50, 2011. Disponível em: <<http://urlib.net/3ERPFQRTW/39UFC7E>>. Acesso em: 31/12/2012.
- ANTUNES, A. F. B. Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial. Tese (Doutorado em Ciências Geodésicas) - Universidade Federal do Paraná, Curitiba, 2003.
- ANTUNES, A. F. B.; LINGNAU, C. Uso dos índices de acurácia para avaliação de mapas temáticos obtidos por meios de classificação digital. In: *Congresso e feira para usuário de geoprocessamento*. 3. ed. Curitiba: Sagres, 1997.
- ARCOVERDE, G. F. B.; EIPHANIO, J. C. N.; MARTINS, V. A.; MAEDA, E. E.; FONSECA, L. M. G. Mapeamento de *citrus*: avaliação de classificações por árvore de decisão. *Revista Brasileira de Cartografia*, v. 62, n. 1, p. 91-102, mar/ 2010.
- BAATZ, M.; SCHÄPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: *XII Angewandte Geographische Informationsverarbeitung, AGIT Symposium. Proceedings...* Karlsruhe, Alemanha: Herbert Wichmann Verlag, Salzburg - Áustria, p. 12-23, 2000.
- 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*, 58: 239–258. 2004.
- BERNARDES, T. Caracterização do ambiente agrícola do Complexo Serra Negra por meio de sensoriamento remoto e sistemas de informação geográfica. Dissertação (Mestrado). Universidade Federal de Lavras, Minas Gerais, 2006, 119p. Disponível em: <<http://www.epamig.br/geosolos/MaterialSite/Teses/Tiago/Tiagodissertacao.pdf>>. Acesso em: 05 de outubro de 2011.
- BERNARDES, T.; ALVES, H.M.R.; VIEIRA, T.G.C. Classificação automática de imagens de satélite no mapeamento da região cafeeira de Patrocínio, MG. In.: *Simpósio de Pesquisa dos Cafés do Brasil, 5,2007,SP. Anais...* Minas Gerais:EPAMIG,2005.
- BERNARDI, H. V. F.; DZEDZEJ, M.; CARVALHO, L. M. T.; ACERBI JR, F. W. Classificação digital do uso do solo comparando os métodos “*pixel a pixel*” e orientado ao objeto em imagem QuickBird. Universidade Federal de Lavras - UFLA. In: *Anais XIII Simpósio Brasileiro de Sensoriamento Remoto (SBSR)*. Florianópolis: INPE, p. 5595-5602, 2007.
- BIAS, Edilson de Souza; BAPTISTA, Gustavo Macedo de Mello; LOMBARDO, Magda Adelaide. Potencialidades e Limitações das Imagens de Alta Resolução Ikonos II Para Estudos de Planejamento Urbano. *Geografia (Rio Claro. Impresso)*, v. 34, p. 329-346, 2009.
- BICAS, H. E. A. Mensurações em ciência. *Arquivos brasileiros de oftalmologia*. v. 66, n. 4, p. 531-37, 2003.
- BINIS, L. S.; FONSECA, L. M. G.; ERTHAL, G. J.; II, F. M. Satellite imagery segmentation: a region growing approach. *Anais VIII Simpósio Brasileiro de Sensoriamento Remoto, Salvador: INPE*, p. 677-80, 1996.
- BISHOP, Y. M.; FEINBERG, S. E. & HOLLAND, P. W. *Discrete Multivariate Analysis - Theory and Practice*. Cambridge, Mass., the mit press, 357 p., 1975.

- BOARDMAN, J. W.; KRUSE, F. A.; GREEN, R. O. Mapping target signatures via partial unmixing of AVIRIS data. In: JPL Airborne Earth Science Workshop, 5, Pasadena-USA. Proceedings...: Jet Propulsion Laboratory, p. 23-26, 1995.
- BRITES, R.S.; SOARES, P.S.; RIBEIRO, C. A. A. S. Comparação de desempenho entre três índices de exatidão aplicados a classificação de imagens orbitais. In: Anais Simpósio Brasileiro de Sensoriamento Remoto, 8, Salvador: INPE, 1996.
- BRITES, R.S.; SOARES, V.P.; RIBEIRO, C.A.A.S. Efeitos da estratégia de amostragem na exatidão reportada pelo índice de *kappa* na classificação de imagens orbitais. In: Anais Simpósio Brasileiro de Sensoriamento Remoto, 8, Salvador: INPE, 1996.
- BÜCKNER, J.; PAHL, M.; STAHLHUT, O.; LIEDTKE, C.-E. GEOAIDA – A knowledge-based automatic image data analyzer for remote sensing data. In: ICSC Congress on Computational Intelligence Methods and Applications. Bangor, Wales-UK. Proceedings of the Congress on Computational Intelligence Methods and Applications - CIMA 2001.
- CARVALHO JR, O. A.; GUIMARÃES, R. F.; MARTINS, E S.; CARVALHO, A. P. F.; GOMES, R. A. T. Análise comparativa do processo de identificação automatizada de membros finais a partir de imagens com diferentes resoluções espectrais para a região de Niquelândia (AVIRIS, ETM + e ASTER). Revista Brasileira de Geografia, v. 23, n. 1, p. 39-50, 2005.
- CARVALHO JR, O. A.; MENESES, P. R. Spectral Correlation Mapper (SCM): an improving Spectral Angle Mapper. In: Annual JPL Airborne Earth Science Workshop, 9, Pasadena-USA, Proceedings - JPL Publication, 00-18, p. 65-74, 2000.
- CARVALHO, M. V. A. Classificação da cobertura e uso do solo com imagens Worldview II utilizando mineração de dados e análise baseada em objetos. [Dissertação de mestrado em sensoriamento remoto - Instituto Nacional de Pesquisas Espaciais]. São José dos Campos, p. 201, 2011. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3ACT3BL>>. Acesso em: 31/12/2012.
- CARVALHO, M. V. A.; Kux, H. J. H.; Florenzano, T G.; MOREIRA, M. A. Fusão de imagens aplicada a estudos urbanos: avaliação de diferentes técnicas em imagens WorldView-2. In: Simpósio brasileiro de Sensoriamento Remoto, 15. (SBSR), 2011, Curitiba. Anais ... São José dos Campos: INPE, 2011. p. 941-948. DVD, Internet. ISBN 978-85-17-00056-0 (Internet), 978-85-17-00057-7 (DVD). Disponível em: <<http://urlib.net/3ERPFQRTRW/39UR8JP>>. Acesso em: 10/02/2013.
- CODEPLAN - Companhia de Planejamento do Distrito Federal. Pesquisa Distrital por Amostra de Domicílios. Sobradinho – PDAD 2011. Brasília-DF, out./2011.
- CONEL, J. E; HOOVER, G; NOLIN, A; ALLEY, R; MARGOLIS, J. Empirical Relationships Among Semi-Arid Landscape Endmembers Using the Spectral Angle Mapper (SAM) Algorithm, Summaries of the 4th Annual JPL Airborne Geoscience Workshop, JPL Pub-92-14, AVIRIS Workshop. Jet Propulsion Laboratory, Pasadena, CA, pp. 150-151. 1992.
- CONGALTON, R. A Review of Assessing the Accuracy of Classification Remotely Sensed Data. Remote Sensing of Environment, USA, No 37, p. 35-36, 1991.
- CONGALTON, R. G.; GREEN, K. Assessing the accuracy of remotely sensed data: principles and practices. New York: Lewis Publisher. p. 137, 1999.
- CORREIA, V. R. M.; MONTEIRO, A. M. V.; CARVALHO, M. S.; WERNECK, G. L. Uma aplicação do sensoriamento remoto para a investigação de endemias urbanas. Cadernos de Saúde Pública. Rio de Janeiro, v. 23, n. 5, p. 1015-28, 2007.
- COSTA, G. A. O. P.; FEITOSA, R. Q.; FONSECA, L. M. G.; OLIVEIRA, D. A. B.; FERREIRA, R. S.; CASTEJON, E. F. Knowledge-Based Interpretation of Remote Sensing Data with the Interimage System: Major Characteristics and Recent Developments. In: Proceedings of the 3rd International Conference on

- Geographic Object-Based Image Analysis - GEOBIA 2010. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XXXVII. ITC, Enshede. 2010.
- COSTA, G. A. O. P.; PINHO, C. M. D.; FEITOSA, R. Q.; ALMEIDA, C. M., KUX, H. J. H.; FONSECA, L. M. G.; OLIVEIRA, D. A. B. INTERIMAGE: Uma Plataforma Cognitiva Open Source para a Interpretação Automática de Imagens Digitais. *Revista Brasileira de Cartografia* 60, 331-337. 2008.
- COUTINHO, A. C. Segmentação e classificação de imagens Landsat-TM para o mapeamento dos usos da terra na região de Campinas, SP. [Dissertação de mestrado em ciências – Instituto de Biociências]. Universidade de São Paulo, São Paulo, p. 150, 1997.
- CRUZ, C. B. M. Classificação orientada a objetos no mapeamento dos remanescentes da cobertura vegetal do bioma Mata Atlântica, na escala 1:250.000. In: *Anais III Simpósio de Sensoriamento Remoto*, Florianópolis, p. 5691-98, 2007.
- DEFINIENS IMAGING. eCognition: user guide. p.468, 2004. Disponível em: <<http://www.definiensimaging.com/down/ecognition>>. Acesso em: 31/12/ 2012.
- DEMATTE, J. A. M.; TOLEDO, A. M. A.; SIMOES, M. S. Metodologia para reconhecimento de três solos por sensores: laboratorial e orbital. *Revista Brasileira de Ciência do Solo.*, vol.28, n.5, pp. 877-889, 2004.
- DIGITAL GLOBE. Spectral response for Digital Globe WorldView 1 and WorldView 2 Earth imaging instruments. 2012b. Disponível em: <http://www.satimagingcorp.com/media/pdf/WV1_WV2_SpectralResponse.pdf>.
- DIGITAL GLOBE. Worldview II. 2012. Disponível em: <<http://www.digitalglobe.com/downlo-ads/WorldView2-DS-WV2-Web.pdf>> Acesso em: 13/08/2012.
- DLUGOSZ, F. L.; ROSOT, N. C.; ROSOT, M. A. D.; OLIVEIRA, Y. M. M. Índice para a avaliação de segmentação de imagens. *Revista Floresta, Curitiba*, v. 39, n. 1, p. 131-43, jan./mar. 2009.
- ECKERT, S. Improved forest biomass and carbon estimations using texture measures from Worldview II satellite data. *Remote Sensing*, n. 4, p. 810-29, 2012.
- EHLERS, M. Sensoriamento remoto para usuários de SIG – sistemas e métodos: as exigências e a realidade. In: BLASCHKE, T.; KUX, H. (ed.) *Sensoriamento remoto e SIG avançados*. São Paulo: Oficina de Textos, cap. 2, p. 20-32, 2005.
- ENVIRONMENTAL SYSTEMS RESEARCH INSTITUTE (ESRI). ArcGIS Professional GIS for the desktop, versão 9.3, 2008.
- FEITOSA, R. Q.; MATTOS, C.; SANTOS, R. V.; REGO, L. F. G.; PEREIRA, A. A. C. Impacto de técnicas baseadas em conhecimento na análise de imagens de média resolução para mapeamento do desflorestamento na Amazônia. In: *Anais Simpósio Brasileiro de Sensoriamento Remoto*, 12, Goiânia: INPE, p. 4065-72, 2005.
- FERNANDES, R. E. F.; SANTOS, A. P.; COSTA, M. F.; COSTA, F. F. Avaliação da acurácia em levantamentos cinemáticos em tempo real aplicando a técnica RTK. *Anais do III Simpósio Brasileiro de Geomática*, Presidente Prudente-SP, v. 1, p. 240-45, 2012.
- FERREIRA, R. S. Uma Abordagem multiescalar, multicritério para a segmentação de imagens. [Dissertação de mestrado de engenharia elétrica - Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica]. Rio de Janeiro, 2011.
- FIGUEIREDO, G. C.; VIEIRA, C.A.O. Estudo do comportamento dos índices de exatidão global, *Kappa* e *Tau*, comumente usados para avaliar a classificação de imagens de sensoriamento remoto. In: *Anais Simpósio Brasileiro de Sensoriamento Remoto*, 13, Florianópolis: INPE, p. 5755-62, 2007.

- GREEN, A. A.; BERMAN, M.; SWITZER, P.; CRAIG, M. D. A transformation for ordering multispectral data in terms of image quality with implications for noise removal. *IEEE Transactions on Geoscience and Remote Sensing*, v. 26, n.1, p. 65-74, 1988.
- GREEN, K. The potential and limitations of remote sensing and GIS in providing ecological information. In: SAMPLE, V. A. (ed). *Remote sensing and GIS in ecosystem management*. Washington: Island Press, part. 4, cap. 19, p. 327-36, 1994.
- IMMITZER, M.; ATZBERGER, C.; KOUKAL, T. Tree species classification with random forest using very high spatial resolution 8-band Worldview II satellite data. In: *Remote Sensing*, v. 4(9), p. 2661-93, 2012.
- INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE) - Manuais: tutorial de geoprocessamento SPRING, 2008.
- JENSEN, J. R. Remote sensing of vegetation. In: *Remote sensing of the environment, an Earth resource perspective*. Upper Saddle River-NJ: Prentice Hall, p. 333-377, 2000.
- KAMAGATA, N.; AKAMATSU, Y.; MORI, M.; QING LI, Y.; HOSHINOY, Y.; HARA, K. Comparison of pixel-based and object-based classifications of high resolution satellite data in urban fringe areas. In: *Proceedings of the 26th Asian Conference on Remote Sensing*. Hanoi, Vietnam. Nov./2005.
- KLECKA, W. R. *Discriminant Analysis*. SAGE Publications, Inc., Beverly Hills, California, 71 p., 1980.
- KÖRTING, T. S. *Classificação de imagens por regiões*. São José dos Campos, 2006.
- KRUSE, F. A.; BOARDMAN, J. W.; HUNTINGTON, J. F. Comparison of airborne hyperspectral data and EO-1 Hyperion for mineral mapping. *IEEE Transactions on Geoscience and Remote Sensing*, v. 41, n.6, p. 1388-1400, 2003.
- KRUSE, F. A.; BOARDMAN, J. W.; LEFKOFF, A. B.; HEIDEBRECHT, K. B.; SHAPIRO, A.T.; BARLOON, P. J.; GOETZ, A. F. H. The spectral image processing system (SIPS) – interactive visualization and analysis of imaging spectrometer data. *Remote Sensing of Environment*, v. 44, p.145-163, 1993.
- KURY, E. B.; VIEIRA, C. A. O. *Classificação automática de imagens de alta resolução*. Viçosa-MG, Disponível em: <<http://www.ufv.br/nugeo/ufvgeo2002/resumos/9-eduardo.pdf>> acesso em: 06 de março de 2013.
- KUX, H. J. H.; SOUZA, U. D. V. Object-based image analysis of Worldview II satellite data for the classification of mangrove areas in the city of São Luís, Maranhão State, Brazil. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. I-4, n. 2012, p. 95-100, 2012.
- LANDIS, J. R; KOCH, G. G. The measurement of observer agreement for categorical data. *Biometrics*, v.33, n.1,p. 159-174, 1977.
- LEONARDI, F. *Abordagens cognitivas e mineração de dados aplicadas a dados ópticos orbitais e de laser para a classificação de cobertura do solo urbano*. (sid.inpe.br/mtc-m19@80/2010/03.17.11.42-TDI). [Dissertação de mestrado em sensoriamento remoto - Instituto Nacional de Pesquisas Espaciais]. São José dos Campos, p. 162, 2010. Disponível em: <<http://urlib.net/8JMKD3MGP7W/376H8M2>>. Acesso em: 30/12/2012.
- LEVADA, A. L. M. *Combinação de modelos de campos aleatórios markovianos para classificação contextual de imagens multiespectrais*. 146p. Tese (Doutorado) - Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos, 2010.
- LIOTTE, S.V; MACEDO, A. B. *Utilização de técnicas de geoprocessamento para apoio ao planejamento físico-territorial do município de Pariquera-Açu*. Universidade de São Paulo. São Paulo, 2000.
- LUIZ, N. B.; ANTUNES, A. F. B.; TAVARES JR, J. B. Segmentação multirresolução e classificação orientada a objetos aplicados a imagens Spot-5 para o mapeamento do uso da terra. *Revista Floresta*, Curitiba-PR, v. 40, n. 2, p. 429-46, abr./jun. 2010.

- MENESES, P. R.; ALMEIDA, T. Introdução ao processamento de imagens de sensoriamento remoto. 1. ed. Brasília: CNPq, v. 1, p. 256, 2012.
- MIKHAIL, E.; ACKERMAN, F. Observations and least squares. United States: University Press of America, p. 497, 1976.
- MONICO, J. F. G.; POZ, A. P. D.; GALO, M.; SANTOS, M. C.; OLIVEIRA, L. C. Acurácia e precisão: revendo os conceitos de forma acurada. Boletim de Ciências Geodésicas, sec. Comunicações, Curitiba, v. 15, n. 3, p. 469-83, jul.-set./2009.
- MOREIRA, M. A.; CARDOSO, V.; FREITAS, R. M.; RUDORFF, B. F. Comparação da resposta espectral de alvos em imagens CBERS-2/CCD e LANDSAT-5/TM. Anais XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia: INPE, p. 1027-34, 2005.
- MOREIRA, R. C.; GALVÃO, L. S. Identificação espectral SAM em áreas urbanas com imagem do sensor HSS. In: Simpósio Brasileiro de Sensoriamento Remoto, 14., 2009, Natal. Anais... São José dos Campos: INPE, p. 1159-1166, 2009.
- MUTANGA, O.; ADAM, E.; CHO, M. A. High density biomass estimation for wetland vegetation using Worldview II imagery and random forest regression algorithm. International Journal of Applied Earth Observation and Geoinformation, v. 18, p. 399-406, 2012.
- NAVULUR, K. Multispectral image analysis using the object-oriented paradigm. Boca Raton: Taylor & Francis Group, p. 165, 2006.
- NOVACK, T. Classificação da cobertura da terra e do uso do solo urbano utilizando o sistema InterIMAGE e imagens do sensor Quickbird. 214p. INPE-16594-TDI/1580. [Dissertação de mestrado em sensoriamento remoto. INPE – Instituto Nacional de Pesquisas Espaciais]. São José dos Campos, 2009. Disponível em: <<http://mtc-m18.sid.inpe.br/col/sid.inpe.br/mtcm18%4080/200-9/08.31.21.23/doc/publicacao.pdf>>. Acesso em: 07/01/2013.
- NOVACK, T. *et al.* Análise dos dados do satélite Worldview II para a discriminação de alvos urbanos semelhantes com base em algoritmos de seleção de atributos. Anais XV Simpósio Brasileiro de Sensoriamento Remoto – SBSR, Curitiba-PR, 2011.
- OLIVEIRA, J. C.; SILVA, J.M.F. Influência da segmentação no processo de classificação por região. In: Anais XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia-GO, 2005.
- PAHL, M. Arquitetura de um sistema baseado em conhecimento para a interpretação de dados de sensoriamento remoto de múltiplos sensores. 95 p. (INPE-15211-TAE/71). PhD Thesis - Universidade de Hannover, São José dos Campos. 2008.
- PEDROSA, S. A. Discriminação espectral de variações faciológicas de carbonatos por meio de espectrorradiometria e imagens ASTER na região de Serra do Ramalho-BA. [Dissertação de Mestrado – UNB]. Brasília-DF, 2010.
- PINHEIRO, E. S.; KUX, H. J. H. Imagens Quickbird aplicadas ao mapeamento do uso e cobertura da terra do centro de pesquisas e conservação da natureza pró-mata. In: Sensoriamento Remoto e SIG avançados: novos sistemas sensores, métodos inovadores. São Paulo: Oficina de Textos, p. 286, 2005.
- PINHO, C. M. D. Análise orientada a objetos de imagens de satélite de alta resolução espacial aplicada á classificação de cobertura de solo no espaço intra-urbano: o caso de São José dos Campos - SP. [Dissertação de mestrado em sensoriamento remoto - Instituto Nacional de Pesquisas Espaciais] São José dos Campos, p. 180, 2006.
- PINHO, C. M. D.; FEITOSA, F. F.; KUX, H. J. H. Classificação automática de cobertura do solo urbano em imagens IKONOS: comparação entre a abordagem “*pixel a pixel*” e orientada a objetos. In: XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia: INPE, p. 4217-24, 2005.

- PRADO, F. A. Sistema hierárquico de classificação para mapeamento da cobertura da terra nas escalas regional e urbana. [Dissertação de mestrado da Universidade Estadual Paulista, Campus de Presidente Prudente]. São Paulo, p. 164, 2009.
- PU, R.; LANDRY, S. A comparative analysis of high spatial resolution IKONOS and Worldview II imagery for mapping urban tree species. In: Remote Sensing of Environment, v. 124, p. 516–533, 2012.
- RIBEIRO, B. M. G. Avaliação das imagens Worldview II para o mapeamento da cobertura do solo urbano utilizando o sistema InterIMAGE. INPE-16761-TDI/1689. [Dissertação de mestrado em sensoriamento remoto - INPE - Instituto Nacional de Pesquisas Espaciais]. São José dos Campos, p. 177, 2010. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-19@80/2010/08.03.12.52.20>>. Acesso em: 31/12/2012.
- RIBEIRO, S. R. A.; SANTOS, D. R.; CENTENO, J. A. S. Aplicação da metodologia de dados orientada a objeto na classificação de uma área urbanizada, utilizando uma imagem digital obtida por meio da tecnologia do *laser scanner*. In: Anais em CD-ROM do Simpósio Brasileiro de Geomática, Presidente Prudente, 2002.
- RICHARDS, J. A.; JIA, X. Remote sensing digital image analysis: an introduction. 4. ed. New York: Springer, p. 476, 2006.
- RUDORFF, C. M. Estudo da composição das águas da Planície Amazônica por meio de dados de reflectância do sensor Hyperion/EO-1 e de espectrômetro de campo visando à compreensão da variação temporal dos seus constituintes opticamente ativos / C. M. Rudorff. – São José dos Campos: INPE, 2006.
- SHIMABUKURO, M. T. Avaliação de classificadores espectrais de imagens Lansat-TM em áreas rurais densamente ocupadas: o caso da região de Brotas e Torrinha - São Paulo. [Dissertação de mestrado em biologia vegetal - Universidade Estadual de Campinas]. Campinas, p. 193, 1996.
- SILVA, A. F. Geoestística e sensoriamento remoto na classificação de imagens em áreas cultivadas com citros. [Dissertação de mestrado em agronomia - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista]. Botucatu, p. 83, 2011.
- SOUZA, U. D. V. Classificação da cobertura e do uso do solo urbano de São Luís (MA), com imagens Worldview II utilizando mineração de dados e o sistema Interimage. (sid.inpe.br/mtc-m19/2012/10.17.17.34-TDI). [Dissertação de mestrado em sensoriamento remoto - Instituto Nacional de Pesquisas Espaciais]. São José dos Campos, p. 112, 2012. Disponível em: <<http://mtc-m19.sid.inpe.br/col/sid.inpe.br/mtc-m19/2012/10.17.17.34/doc/publicacao.pdf>>. Acesso em: 02/01/2013.
- SOUZA, U. D. V.; ALFAYA, F. A. V. S.; KUX, H. J. H. Contribuição das novas bandas espectrais do satélite Worldview II para a classificação de tipos vegetais em *habitats* costeiros: resultados iniciais. In: Anais do Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 15, Curitiba: INPE, p. 9040-47, 2011. DVD, Internet. ISBN 978-85-17-00056-0 (Internet), 978-85-17-00057-7 (DVD). Disponível em: <<http://urlib.net/3ERPFQRTRW/3A58J35>>. Acesso em: 31/12/2012.
- SPRING. (1996) - Sistema de Processamento de Informações Georeferenciadas, Instituto Nacional de Pesquisas Espaciais, INPE Disponível em, Disponível em <<http://www.inpe.br/spring>> Acesso em: 02/01/2013.
- STORY, M.; CONGALTON, R. G. Accuracy assessment: a user's perspective. Photogrammetric Engineering and Remote Sensing, v. 52: p. 397-99, 1986.
- TORRIJOS CADENA, G. 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 em ciências cartográficas, Universidade Estadual Paulista - Faculdade de Ciências e Tecnologia]. São Paulo, 2011. Disponível em: <http://www4.fct.unesp.br/pos/cartografia/docs/teses/d_cadena_gt.pdf> Acesso em: 02/01/2013.
- VIEIRA, M. A. Análise de imagem orientada a objeto e mineração de dados aplicadas ao mapeamento da cultura da cana-de-açúcar. (sid.inpe.br/mtc-m19@/2010/04.08.17.43-TDI). [Dissertação de mestrado em sensoriamento remoto - Instituto Nacional de Pesquisas Espaciais]. São José dos Campos, p. 110, 2010. Disponível em: <<http://urlib.net/8JMKD3MGP7W/37A6SQ8>>. Acesso em: 02/01/2013.

- XIAOXIA, S.; JIXIAN, Z.; ZHENGJUN, L. A comparison of object-oriented and pixel-based classification approaches using quickbird imagery. Proceedings ISPRS - International Society of Photogrammetry and Remote Sensing, 2005.
- YUHAS, R. H.; GOETZ, AFH; BOARDMAN, J. W. Discrimination Among Semi-Arid Landscape Endmembers Using Spectral Angle Mapper (SAM) Algorithm, Summaries of the 4th Annual JPL Airborne Geoscience Workshop, JPL Pub-92-14, AVIRIS Workshop. Jet Propulsion Laboratory, Pasadena, CA, pp. 147-150. 1992
- ZANARDO, F. H.; SILVA, H. R.; ZOCOLLER, J. V. S.; MAGALHÃES, N. A. Avaliação e comparação de métodos de classificação de imagens de satélites, utilizados pelo *software* Spring no estudo da microbacia hidrográfica do Córrego Acampamento, em Dirce Reis (SP). In: XXI Congresso de Iniciação Científica (CIC) - UNESP, São José do Rio Preto, 2009.
- ZENGEYA, F. M.; MUTANGA, O.; MURWIRA, A. Linking remotely sensed forage quality estimates from Worldview II multispectral data with cattle distribution in a savanna landscape. In: International Journal of Applied Earth Observation and Geoinformation, v. 21, p. 513-24, 2013.