

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE ENERGIA**

Grasiela de Oliveira Rodrigues

**ANÁLISE DA ACURÁCIA TEMÁTICA DAS CLASSIFICAÇÕES DE
IMAGENS ORBITAIS AVNIR-2/ALOS, CCD/CBERS-2 E TM/LANDSAT-5,
COMPARANDO AS ABORDAGENS DE MÁXIMA VEROSSIMILHANÇA E
FUZZY**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia da Energia como parte dos requisitos para obtenção do Título de Mestre em Ciências em Engenharia de Energia.

Área de Concentração: Energia, Sociedade e Meio Ambiente.

Orientador: Prof. Dr. Francisco Antônio Dupas

Co-orientadora: Prof^a. Dr^a. Maria de Lourdes Bueno Trindade Galo

Novembro de 2009

Itajubá - MG

FICHA CATALOGRÁFICA



Ministério da Educação
UNIVERSIDADE FEDERAL DE ITAJUBÁ
Criada pela Lei nº 10.435, de 24 de abril de 2002

A N E X O II

FOLHA DE JULGAMENTO DA BANCA EXAMINADORA

Título da Dissertação: **"Análise da Acurácia Temática de Classificações de Imagens Orbitais AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5, Comparando as Abordagens de Máxima Verossimilhança e Fuzzy"**

Autor: **Grasiela de Oliveira Rodrigues**

JULGAMENTO

Examinadores	Conceito	Rubrica
	A = Aprovado - R = Reprovado - I = Insuficiente	
1º	APROVADA	Max
2º	APROVADA	Nivea
3º	Aprovada	M. Lourdes
4º	aprovada	Francisco A. Dupas

Observações:

- (1) O Trabalho será considerado Aprovado se todos os Examinadores atribuírem conceito A.
- (2) O Trabalho será considerado Reprovado se forem atribuídos pelos menos 2 conceitos R.
- (3) O Trabalho será considerado Insuficiente (I) se for atribuído pelo menos um conceito R. Neste caso o candidato deverá apresentar novo trabalho. A banca deve definir como avaliar a nova versão da Dissertação.

Este documento terá a validade de 60 (sessenta) dias a contar da data da defesa da Dissertação.

Resultado Final: Conceito: A, ou seja, APROVADA

Observações:

Itajubá, 23 de novembro de 2009.

Dr. Maximiliano Luis Faundez-Abans
1º Examinador - LNA

Prof.ª Dr.ª Nivea Adriana Dias Pons
2º Examinador - UNIFEI

Prof.ª Dr.ª Maria de Lourdes Bueno Trindade Galo
3º Examinador - UNESP - (Co-Orientadora)

Prof. Dr. Francisco Antonio Dupas
4º Examinador - UNIFEI - (Orientador)

“Mestre não é quem sempre ensina, mas quem de repente aprende.”

João Guimarães Rosa

*Aos meus pais, Nilda e Joaquim,
pela confiança e por me ensinarem a lutar por aquilo que sonho;
ao meu irmão Rudy,
por todo suporte e consideração e
ao Bob, meu noivo,
por seu amor, paciência, compreensão e carinho...*

...dedico este trabalho.

Agradecimentos

Início agradecendo a Deus, por se fazer presente em todos os momentos da minha vida e aos meus pais pela confiança incontestável no meu potencial.

Agradeço ao Prof. Dr. Francisco Dupas agradeço não só pela orientação e dedicação para com o meu trabalho, me incentivando constantemente a melhorá-lo, mas principalmente por despertar em mim uma forma diferente de cobrança e superação.

Ao NEPA – Núcleo de Estudos, Planejamento Ambiental e Geomática, pelas imagens e fotografias aéreas utilizadas neste trabalho e por toda a troca de aprendizado. Em especial, gostaria de agradecer a Fernanda Paes, Wilmer “Alemão”, Taciana, Rafael Eugênio, Márcia Magalhães, Rogério Coli, Diego “violeiro”, Érick Viana, Antônio Carlos (Juninho), André Silveira (Grilo) e o Marcos sobretudo pela amizade que persiste, meu muito obrigada.

Ao amigo Prof. Dr. Marcelo Ribeiro Barison que, na condição de profissional, me orientava com suas experiências e, na condição de amigo, me convidava a “espairecer”, obrigada.

A Douglas Ricardo de Azevedo Medeiros, meu noivo, pelo apoio incondicional, por todo amor, dedicação e por infinitas palavras de incentivo sempre acreditando em mim e no meu trabalho, emocionadamente, obrigada.

Meu agradecimento, também emocionado, ao meu irmão Rudy, por algumas conversas sugestivas e, especialmente por sempre me dizer “calma” nas horas em que a palavra que eu mais carecia ouvir era “calma”.

Ao Refúgio das Pererecas, principalmente nas figuras de Ingrid, Aline (Coração), Andressa, Dianinha e Alessandra que acompanharam grande parte do meu trabalho e me ajudaram nas horas em que eu carecia de distração (e também nas horas em que não carecia). Agradeço pelos momentos em que eu precisava “escrever” e surgia alguém perguntando “o que você tá fazendo, Gra?” e, independente da minha resposta, conseguiam minha desatenção. Agradeço a Fatinha que nas terças e quintas coloria a minha vida e que me será sempre exemplo de determinação, lealdade, força e alegria, muito obrigada.

Agradeço também pelo companheirismo dos amigos Igor Manso e de Thales L. B. Sarlas, à família Zampieri, Daniela, Leonardo e Fábio, por sempre serem tão prestativos e pela amizade.

Agradeço a Fernanda de Almeida Prado, da UNESP de Presidente Prudente, pelas conversas esclarecedoras.

À CAPES pelo apoio financeiro.

*“Eu poderia suportar, embora não sem dor, que tivessem morrido todos os meus amores,
mas enlouqueceria se morressem todos os meus amigos!” (Vinicius de Moraes)*

*“A alguns deles não procuro, basta-me saber que eles existem.
Esta mera condição me encoraja em seguir em frente pela vida...
Mas, porque não os procuro com assiduidade,
não posso lhes dizer o quanto gosto deles. “Eles não iriam acreditar.” (Paulo Sant’Ana)*

SUMÁRIO

Página

LISTA DE FIGURAS	
LISTA DE TABELAS	
RESUMO	vii
ABSTRACT	viii
CAPÍTULO 1 - INTRODUÇÃO	1
1.1. Contextualização do assunto.....	1
1.2. Objetivos.....	3
1.3. Justificativa	3
1.4. Estrutura do trabalho.....	4
CAPÍTULO 2 - REVISÃO BIBLIOGRÁFICA	6
2.1 Sensoriamento Remoto	6
2.1.1 Comportamento espectral dos alvos	8
2.2 Sistemas Sensores	14
2.2.1 Resolução.....	16
2.2.2 Sistemas Sensores Orbitais	18
2.3 Classificação da cobertura do solo a partir de imagens de Sensoriamento Remoto.....	22
2.3.1 Classificação de imagens	23
2.3.2 Classificação pelo método da Máxima Verossimilhança (MAXVER)	25
2.3.3 Classificação Fuzzy	28
2.4 Reconhecimento do grau de incerteza	31
CAPÍTULO 3 - MATERIAIS E MÉTODO	34
3.1 Materiais	34
3.2 Localização da área de estudo	35
3.3 Método	36
3.3.1 Objetivos.....	38
3.3.2 Fotografias Aéreas	38
3.3.3 Imagens de Sensoriamento Remoto: AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5	40
3.3.4 Recorte das imagens	40
3.3.5 Classificações digitais pelo método da Máxima Verossimilhança das imagens dos sensores AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5	41
3.3.6 Matriz do erro – Qualificação do método da Máxima Verossimilhança.....	42
3.3.7 Desenvolvimento de assinaturas Fuzzy	43
3.3.8 Cobertura do solo utilizando a classificação Fuzzy para imagens dos sensores AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5.....	45
3.3.9 Matriz do erro – Qualificação da classificação Fuzzy.....	45
3.3.10 Resultados e discussão.....	46
3.3.11 Conclusões.....	46
CAPÍTULO 4 - RESULTADOS E DISCUSSÕES	47

4.1	Demarcas da área de estudo.....	48
4.2	Mapa de cobertura do solo baseado nas fotografias aéreas	51
4.3	Classificação pelo método da Máxima Verossimilhança	56
4.3.1	Cobertura do solo utilizando imagens do sensor AVNIR-2/ALOS.....	56
4.3.2	Cobertura do solo utilizando imagens do sensor CCD/CBERS-2.....	59
4.3.3	Cobertura do solo utilizando imagens do sensor TM/LANDSAT-5	62
4.4	Classificação Fuzzy	64
4.4.1	Cobertura do solo utilizando imagem do sensor AVNIR-2/ALOS	64
4.4.2	Cobertura do solo utilizando imagem do sensor CCD/CBERS-2	68
4.4.3	Cobertura do solo utilizando imagem do sensor TM/LANDSAT-5	72
4.5	Análises.....	75
4.5.1	Mapeamentos utilizando imagem do sensor AVNIR-2/ALOS	75
4.5.2	Mapeamentos utilizando imagem do sensor CCD/CBERS-2	78
4.5.3	Mapeamentos utilizando imagem do sensor TM/LANDSAT-5.....	80
4.5.4	Comparação quanto à área dos temas – Classificação por Máxima Verossimilhança	82
4.5.5	Comparação quanto à área dos temas – Classificação Fuzzy.....	85
CAPÍTULO 5 - CONCLUSÕES		88
REFERÊNCIAS BIBLIOGRÁFICAS		90

LISTA DE FIGURAS

	Página
Figura 2.1 – Espectro eletromagnético.	7
Figura 2.2 – Interações entre a energia eletromagnética e a superfície de um corpo.	8
Figura 2.3 – Curvas espectrais de solos contendo diferentes porcentagens de água.	11
Figura 2.4 – Influência da porcentagem de água na resposta espectral das folhas.	12
Figura 2.5 – Comportamento espectral da água nos seus três estados físicos.	13
Figura 2.6 – Curvas de reflectância obtidas para o Rio Tietê, o Rio Piracicaba e para o reservatório de Barra Bonita, estudo de (Steffen et al., 1992).	13
Figura 2.7 – Comportamento espectral do concreto e do asfalto.	14
Figura 2.8 – Classificação dos sistemas sensores quanto à fonte de radiação, ao princípio de funcionamento e aos tipos de produtos.	15
Figura 2.9 – Regiões do espectro óptico.	16
Figura 2.10 – Bandas espectrais	16
Figura 2.11 – Estrutura e disposição dos sensores no satélite ALOS.	22
Figura 2.12 – Função densidade de probabilidade definida no método da Máxima Verossimilhança.	26
Figura 2.13 – Fronteiras entre um conjunto Fuzzy (A) e um conjunto booleano (B).	28
Figura 3.1 – Localização da área de estudo no município de São Carlos, SP. Recorte de área inserido no limite da bacia hidrográfica do córrego do Feijão e na bacia hidrográfica do Jacaré-Guaçu.	35
Figura 3.2 – Sub-bacias que compõem a bacia hidrográfica do município de São Carlos/SP.	36
Figura 3.3 – Fluxograma geral do método.	37
Figura 3.4 – Seqüência para a soma dos temas gerando o mapa de cobertura do solo baseado nas fotografias aéreas (verdade terrestre).	40
Figura 3.5 – Recorte das imagens utilizadas. Em (a) é focada uma área da cena do sensor AVNIR-2/ALOS; em (b) é mostrado o resultado do recorte mostrado na linha branca de (a) e em (c) encontra-se o resultado final do corte das bandas, representado pela linha verde da imagem (a).	41

Figura 3.6 – Fluxograma da metodologia para a obtenção das matrizes do erro para a classificação Fuzzy.	42
Figura 3.7 – Fluxograma do desenvolvimento das assinaturas Fuzzy.	43
Figura 3.8 – Fluxograma da metodologia para a obtenção das matrizes do erro para a classificação Fuzzy.	45
Figura 4.1 – Fluxograma dos resultados.....	48
Figura 4.2 – Representação da área de estudo selecionada a partir de mosaico de fotografias aéreas.	49
Figura 4.3 – Vetores dos temas digitalizados – base para a elaboração dos mapas de cobertura do solo baseados nas fotografias aéreas para as 3 resoluções espaciais.....	52
Figura 4.4 – Mapa de cobertura do solo baseado nas fotografias aéreas com resolução espacial do sensor AVNIR-2/ALOS.....	53
Figura 4.5 – Mapa de cobertura do solo baseado nas fotografias aéreas com resolução espacial do sensor CCD/CBERS-2.....	54
Figura 4.6 – Mapa de cobertura do solo baseado nas fotografias aéreas com resolução espacial do sensor TM/LANDSAT-5.	55
Figura 4.7 – Áreas de treinamento amostradas para a classificação Máxima Verossimilhança utilizando imagem do sensor AVNIR-2/ALOS.....	56
Figura 4.8 – Classificação da imagem AVNIR-2/ALOS pelo método da Máxima Verossimilhança	57
Figura 4.9 – Áreas de treinamento para a classificação Máxima Verossimilhança utilizando imagens do sensor CCD/CBERS-2.	59
Figura 4.10 – Classificação da imagem CCD/CBERS-2 pelo método da Máxima Verossimilhança	61
Figura 4.11 – Áreas de treinamento para a classificação Máxima Verossimilhança utilizando imagens do sensor TM/LANDSAT-5.....	62
Figura 4.12 – Classificação da imagem TM/LANDSAT-5 pelo método da Máxima Verossimilhança.	63
Figura 4.13 – Classificação Fuzzy da imagem do AVNIR-2/ALOS.	66
Figura 4.14 – Gráfico comparativo entre os erros de omissão obtidos na matriz do erro quando utilizada a classificação Fuzzy e a classificação pelo método da Máxima Verossimilhança quando utilizadas imagens do sensor AVNIR-2/ALOS.	67
Figura 4.15 – Gráfico comparativo entre os erros de omissão e inclusão obtidos na matriz do erro quando utilizada a classificação Fuzzy e a classificação pelo método da Máxima Verossimilhança quanto utilizadas imagens do sensor AVNIR-2/ALOS.....	68

Figura 4.16 – Classificação Fuzzy para imagem CCD/CBERS-2.....	69
Figura 4.17 – Gráfico comparativo entre os erros de omissão obtidos na matriz do erro quando utilizada a classificação Fuzzy e a classificação pelo método da Máxima Verossimilhança quando utilizadas imagens do sensor CBERS-2.....	70
Figura 4.18 – Gráfico comparativo entre os erros de inclusão obtidos na matriz do erro quando utilizada a classificação Fuzzy e a classificação pelo método da Máxima Verossimilhança quando utilizadas imagens do sensor CBERS-2.....	71
Figura 4.19 – Classificação Fuzzy para as imagem TM/LANDSAT-5.	73
Figura 4.20 – Gráfico comparativo entre os erros de omissão obtidos na matriz do erro quando utilizada a classificação Fuzzy e a classificação pelo método da Máxima Verossimilhança quando utilizadas imagens do sensor TM/LANDSAT-5.....	74
Figura 4.21 – Gráfico comparativo entre os erros de inclusão obtidos na matriz do erro quando utilizada a classificação Fuzzy e a classificação pelo método da Máxima Verossimilhança quando utilizadas imagens do sensor TM/LANDSAT-5.....	75
Figura 4.22 – (a) Mapa de cobertura do solo baseado nas fotografias aéreas na resolução do sensor AVNIR-2/ALOS, (b) Classificação pelo método da Máxima Verossimilhança para imagens do sensor AVNIR-2/ALOS e (c) Classificação Fuzzy, utilizando imagens do sensor AVNIR-2/ALOS.	76
Figura 4.23 – (a) Mapa de cobertura do solo baseado nas fotografias aéreas na resolução do sensor CCD/CBERS-2, (b) Classificação pelo método da Máxima Verossimilhança para imagens do sensor CCD/CBERS-2 e (c) Classificação Fuzzy, utilizando imagens do sensor CCD/CBERS-2.....	79
Figura 4.24 –(a) Mapa de cobertura do solo baseado nas fotografias aéreas na resolução do sensor TM/LANDSAT-5, (b) Classificação pelo método da Máxima Verossimilhança para imagens do sensor TM/LANDSAT-5 e (c) Classificação Fuzzy, utilizando imagens do sensor TM/LANDSAT-5.....	81
Figura 4.25 – Distribuição das áreas de cada tema obtidas através da classificação Máxima Verossimilhança em metros quadrados.	84
Figura 4.26 – Distribuição das áreas de cada tema obtidas através da classificação Máxima Verossimilhança em porcentagem.	84
Figura 4.27 – Distribuição das áreas de cada tema obtidas através da classificação Fuzzy em metros quadrados.	87
Figura 4.28 – Distribuição das áreas de cada tema obtidas através da classificação Fuzzy em porcentagem.....	87

LISTA DE TABELAS

	Página
Tabela 2.1 – Características do sensor TM – LANDSAT-5.....	19
Tabela 2.2 – Principais características do sensor CCD do satélite CBERS-2.	20
Tabela 2.3 – Principais características do sensor AVNIR-2/ALOS.	22
Tabela 2.4 – Qualidade do mapeamento temático associada aos valores da estatística Kappa.	33
Tabela 3.1 – Características das imagens brutas antes e após o corte.	42
Tabela 4.1 – Matriz do erro resultante da tabulação cruzada entre o mapa de cobertura do solo da classificação supervisionada resultante da aplicação do método da Verossimilhança da imagem AVNIR-2/ALOS.	58
Tabela 4.2 – Matriz do erro resultante da tabulação cruzada entre o mapa de cobertura do solo da classificação resultante da aplicação do método da Verossimilhança da imagem CCD/CBERS-2.	59
Tabela 4.3 – Matriz do erro resultante da tabulação cruzada entre o mapa de cobertura do solo da classificação resultante da aplicação do método da Verossimilhança da imagem TM/LANDSAT-5.	64
Tabela 4.4 – Área dos temas presentes nos polígonos de amostragem das áreas de treinamento para a elaboração da matriz de partição Fuzzy.	65
Tabela 4.5 – Matriz de partição Fuzzy	65
Tabela 4.6 – Matriz do erro comparando o mapa de cobertura do solo baseado nas fotografias aéreas na resolução espacial do sensor AVNIR-2/ALOS com o mapa de cobertura do solo das imagens do sensor AVNIR-2/ALOS obtido através da classificação Fuzzy.	65
Tabela 4.7 – Área dos temas presentes nos polígonos de amostragem das áreas de treinamento para a elaboração da matriz de partição Fuzzy	68
Tabela 4.8 – Matriz de partição Fuzzy	68
Tabela 4.9 – Matriz do erro comparando o mapa de cobertura do solo baseado nas fotografias aéreas na resolução espacial do sensor CCD/CBERS-2 com o mapa de cobertura do solo das imagens do sensor CCD/CBERS-2 obtido através da classificação Fuzzy.	70
Tabela 4.10 – Área dos temas presentes nos polígonos de amostragem das áreas de treinamento para elaboração da matriz de partição Fuzzy.	72
Tabela 4.11 – Matriz de partição Fuzzy	72
Tabela 4.12 – Matriz do erro comparando o mapa de cobertura do solo baseado nas fotografias aéreas na resolução espacial do sensor TM/LANDSAT-5 com o mapa de cobertura do solo das imagens do sensor TM/LANDSAT-5 obtido através da classificação Fuzzy.	74
Tabela 4.13 – Comparação entre as matrizes do erro dos sensores (Verdade T. = Verdade Terrestre; AR = Área Real [em m ²]; AP = Área Proporcional [%]; NP = Número de Pixels)	83
Tabela 4.14 – Comparação entre as matrizes do erro dos sensores (Verdade T. = Verdade Terrestre; AR = Área Real [em m ²]; AP = Área Proporcional [%]; NP = Número de Pixels)	86

RESUMO

RODRIGUES, G. O.; (2009). “Análise da acurácia temática das classificações de imagens orbitais AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5, comparando as abordagens de Máxima Verossimilhança e Fuzzy”. Dissertação de mestrado – Programa de Pós-Graduação em Engenharia da Energia / UNIFEI – Universidade Federal de Itajubá, Itajubá/MG.

A utilização de classificações digitais no mapeamento da cobertura do solo de bacias hidrográficas permite estudos e planejamento de atividades urbanas e rurais, indicando áreas propícias à exploração agrícola, pecuária ou florestal. Assim, estimar a acurácia de um mapa de cobertura do solo é fundamental para que este seja utilizado adequadamente. Este trabalho analisa área piloto localizada na bacia hidrográfica do município de São Carlos/SP (com aproximadamente 1,6 km² e 5,6 km de perímetro), através de mapeamentos de cobertura do solo obtidos pelos classificadores digitais Máxima Verossimilhança e Fuzzy. Analisa ainda a influência da resolução espacial nos mapeamentos de cobertura do solo, fazendo uso de cenas dos sensores AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5, com resolução espacial de 10, 20 e 30m respectivamente. Primeiramente foram identificados em mosaico de fotografias aéreas coloridas oito tipos de cobertura do solo, os quais foram digitalizados e convertidos em imagens (rasterização) para compor mapas de verdade terrestre para servirem de parâmetros na comparação com os resultados das classificações digitais. Para tanto, em seguida, foram aplicados os classificadores digitais Máxima Verossimilhança e Fuzzy nas cenas dos sensores citados anteriormente. As comparações dos mapas resultantes das classificações com suas respectivas verdades terrestres foram feitas via matrizes do erro e Índices Kappa. Em relação aos Índices Kappa, encontrou-se para a classificação Máxima Verossimilhança 0,4688; 0,5139 e 0,3144 (AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5, respectivamente). Para a classificação Fuzzy obteve-se 0,5418; 0,5332 e 0,3927 (AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5, respectivamente). Houve, portanto, uma melhora de 7,3% quando se aplicou o classificador Fuzzy nas imagens do AVNIR-2/ALOS, 2% no caso das imagens do CCD/CBERS-2 e 3% no caso das classificações provenientes das imagens do TM/LANDSAT-5. Pode-se concluir, considerando apenas a resolução espacial dos sensores, que os resultados correspondentes ao sensor AVNIR-2/ALOS apresentam melhor qualidade, porém o emprego do sensor CCD/CBERS-2 oferece a melhor relação custo/benefício, uma vez que, diferentemente das cenas do AVNIR-2/ALOS, as imagens do CCD/CBERS-2 são disponíveis gratuitamente na rede (assim como as do TM/LANDSAT-5). Verifica-se a relação direta entre acurácia e resolução espacial dos sensores, comprovando-se que a capacidade de um sensor em discernir alvos espectrais é acrescida com o aumento da resolução espacial. Conclui-se também que a qualidade do mapeamento foi superior quando aplicado o classificador Fuzzy, diminuindo consideravelmente o efeito de borda ocorrido pela existência de pixels mistos, dentre outras confusões. A qualidade da classificação (acurácia) pode ser comprometida pelas áreas de transição, muitas vezes abruptas, entre os temas e por variações nas respostas espectrais dos alvos, como a quantidade de água no solo ou na vegetação em diferentes épocas do ano, como ocorreu neste trabalho.

Palavras-chave: AVNIR-2/ALOS, TM/LANDSAT-5, CCD/CBERS-2, resolução espacial, cobertura do solo, Máxima Verossimilhança, Fuzzy, acurácia, Índice Kappa.

ABSTRACT

RODRIGUES, G. O., (2009). "Analysis of Maximum Likelihood and Fuzzy classifiers in mappings of land use using scenes from orbital sensors AVNIR-2 (ALOS), CCD (CBERS-2) and TM (LANDSAT-5) and color aerial photographs and ground truth." Dissertation - Post-graduate in Energy Engineering / UNIFEI – Federal University of Itajuba, Itajuba / MG.

The use of classifications in the digital mapping of land cover of watersheds allows studies and planning activities of urban and rural areas, indicating areas suitable for farming, ranching or forestry. Thus, estimating the accuracy of a map of land cover is essential for it to be used properly. This paper examines a pilot area located in the watershed in São Carlos/SP (approximately 1.6 km² and 5.6 km perimeter) through mapping land cover classifiers obtained by Maximum Likelihood and Fuzzy digital. It also examines the influence of spatial resolution in mapping land cover, using scenes from the sensors AVNIR-2/ALOS, and CCD/CBERS-2 TM/ LANDSAT -5, with spatial resolution of 10, 20 and 30 m respectively. They were first identified in colorful mosaic of aerial photographs of eight land cover types, which were scanned and converted into images (raster) to compose maps of ground truth to serve as parameters in comparison with the results of digital classifications. To do so, then the classifiers were applied digital maximum likelihood and fuzzy scenes of the sensors mentioned above. The comparisons of the resulting maps of the ratings with their respective ground truths were made via the error matrix and Kappa index. Regarding indices Kappa, met for the classification maximum likelihood 0.4688, 0.5139 and 0.3144 (AVNIR-2/ALOS, and CCD/CBERS-2 TM/Landsat-5, respectively). For Fuzzy classification we obtained 0.5418, 0.5332 and 0.3927 (AVNIR-2/ALOS, CCD/CBERS-2 TM/ LANDSAT -5 and, respectively). There was therefore an improvement of 7.3% when we applied the fuzzy classifier in pictures AVNIR-2/ALOS 2% in the case of pictures CCD/CBERS-2 and 3% in the case of classifications derived from TM/LANDSAT-5 images. One can conclude, considering only spatial resolution of sensors, the results corresponding to the sensor AVNIR-2/ALOS have better quality, but the use of CCD/CBERS-2 offers the best value for money, since, AVNIR-2/ALOS unlike the scenes footage of the CCD/CBERS-2 are freely available on the network (as well as the TM/ LANDSAT-5). There is a direct relationship between accuracy and spatial resolution of sensors, proving that the ability of a sensor to discern spectral targets is increased with increasing spatial resolution. It also follows that the quality of the mapping was superior when applied to the fuzzy classifier, reducing considerably the edge effect occurred for the existence of mixed pixels, among other confusions. The classification quality (accuracy) can be endangered by areas of transition, often abrupt, between the themes and variations in spectral signatures of targets, such as the amount of water in soil and vegetation in different seasons, as occurred in this work.

Keywords: AVNIR-2/ALOS, TM/LANDSAT-5, CCD/CBERS-2, spatial resolution, land use, Maximum Likelihood, Fuzzy, accuracy, Kappa index.

CAPÍTULO 1 - INTRODUÇÃO

1.1. Contextualização do assunto

Em decorrência do acelerado crescimento populacional e, simultaneamente, da busca de fontes energéticas, bens de consumo e alimento, os ambientes naturais sofrem agressões que tornam duvidável o futuro sustentável dos ecossistemas (Hogan, 2005 e Karki, 2004). Essas agressões podem ser percebidas em escala temporal ou isoladamente; no decorrer do tempo, ao serem quantificadas as ambições antrópicas através das variáveis ambientais, os resultados são assustadores, fazendo com que inúmeras áreas da ciência se mobilizem e busquem alternativas e medidas mitigadoras pra reverter este quadro.

Surgem então, segundo Allen (2003), conceitos relacionados ao planejamento de bacias hidrográficas (unidades mínimas a serem consideradas nas atividades e estudos), mostrando que quando colocados em exercício, no mínimo denotam um futuro similar ao presente e, ao serem levados a sério, tornam as perspectivas favoráveis aos recursos naturais e principalmente ao homem.

Dentre as principais ferramentas utilizadas no planejamento de bacias hidrográficas, tradicionalmente é feito uso do Sensoriamento Remoto, tornando possível (o planejamento) em pequenas e grandes extensões devido a captura de imagens por sensores presentes em satélites (Novo, 2008), os quais, através de registros da energia refletida por alvos terrestre, convertem-nas em informações, permitindo acesso a dados nas mais diversas e intransitáveis zonas da Terra.

Estes dados são processados resultando em softwares específicos denominados Sistemas de Informações Geográficas – SIG's que através de técnicas de Geoprocessamento e de acordo com interesses específicos, auxiliam em estudos locais e temporais servindo de apoio às tomadas de decisão em projetos de planejamento de bacias hidrográficas.

Uma das variáveis ambientais mais importantes em qualquer escala é o mapeamento da cobertura do solo, o qual mostra, para uma determinada área e utilizando imagens de sensores remotos, como vem sendo aproveitado o solo e os recursos naturais. A importância dessa informação é imprescindível para diversos estudos hidrológicos, de expansão urbana e ocupações ilegais (os quais têm interferências diretas na qualidade dos recursos hídricos e do solo), de análises temporais (para identificar o comportamento de alvos em certo período de tempo, monitorando explorações irregulares de recursos naturais) e, combinado com mapas temáticos (tipo de solo, geologia, hidrografia e outros), pode ser identificado o uso potencial de uma área, dentre diversas aplicações (Mactezuma, 2001).

O Sensoriamento Remoto permite que sejam realizadas classificações quanto à cobertura do solo utilizando inúmeras técnicas, baseadas em interpretação visual ou em análises digitais. Normalmente, as técnicas convencionais de classificação digital de dados em Sensoriamento Remoto consideram que o pixel (unidade elementar de uma imagem) seja classificado em uma única classe de cobertura do solo, desconsiderando sua formação que muitas vezes pode ser mista.

O classificador mais popular para a elaboração de mapas de cobertura do solo é o da Máxima Verossimilhança, o qual apresenta performance satisfatória (Bolstad e Lillesand, 1992) mas não considera o fato de que o pixel, com suas características espectrais, possa ser composto por mais de uma classe de cobertura, fazendo-o ser atribuído à classe com que apresenta maior nível de similaridade (Foody, 1999).

Assim, ao se realizar uma classificação da cobertura do solo de uma área por algum método tradicional, sua acurácia (grau de acerto do classificador empregado para se obter a classificação – Foody, 2001), é comprometida pelas áreas de transição entre temas, compostas por conjunto de pixels mistos, caracterizando o chamado efeito de borda. Assim, surgem classificadores que possibilitam a minimização deste problema, melhorando a qualidade da classificação anteriormente obtida (Foody, 1999).

A classificação Fuzzy considera que os pixels podem ter múltiplas ou parciais classes de pertinência (Foody, 1995), proporcionando indiscutíveis contribuições e vantagens. Ainda, o uso de dois classificadores na obtenção do levantamento da cobertura do solo é bastante útil e prático, contribuindo para o aumento da acurácia dos resultados. Portanto, é indicada a associação do método da Máxima Verossimilhança com o classificador Fuzzy (Liu et al., 2002).

Dentre as maneiras existentes para a verificação do grau de acerto de um processo digital encontra-se a elaboração da matriz do erro, com a qual é obtido o Índice Kappa. Na matriz do erro (ou matriz de confusão) são confrontados dados referentes à verdade de campo e os correspondentes aos obtidos no mapeamento a ser avaliado.

1.2. Objetivos

Os objetivos deste trabalho são:

- verificar e analisar a melhora na qualidade dos mapas da cobertura do solo quando utilizados os classificador Fuzzy juntamente com o da Máxima Verossimilhança para imagens dos sensores AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5;
- comparar os resultados de classificações digitais de imagens provenientes de sensores com resolução espacial distintas (AVNIR-2/ALOS – 10 m, CCD/CBERS-2 – 20 m e TM/LANDSAT-5 – 30 m) e verificar a influência desta propriedade na distinção de alvos terrestres.

1.3. Justificativa

A classificação Fuzzy utiliza o conceito de conjuntos Fuzzy em que uma entidade (um pixel) pode mostrar qualquer cenário possível pertencendo desde a uma única classe até uma pertinência dividida entre todas as classes, ou seja pertencer a mais do que uma categoria (Jensen, 1996). A classificação Fuzzy é uma técnica que, basicamente, transforma valores característicos em valores Fuzzy, entre '0' e '1', indicando o grau de ligação a uma classe específica. O maior grau de pertinência a uma classe determina a classificação final.

Trata-se de uma alternativa para representar modelos de raciocínio imprecisos introduzida em 1965 por Lotfi Zadeh (Zadeh, 1965), em situações onde não cabe a interpretação booleana ou o tratamento de falso/verdadeiro, sim/não, certo/errado (Lima Jr., 2002).

Nesse contexto, introduzi-la ao Sensoriamento Remoto é de grande conveniência, uma vez que:

- é comum a presença nos pixels de múltiplas classes de pertinência para imagens com menor resolução espacial (Foody, 1995) e por isso não é apropriado que esta informação seja desconsiderada;
- expressa a imprecisão de categorias espacialmente distribuídas (como nos casos de mapeamento da cobertura do solo baseados em imagens de sensoriamento remoto) ou oferece informações sobre classes contínuas de cobertura do solo (Islam, 2004);
- a classificação pela Máxima Verossimilhança apresenta saídas rígidas (Campbel, 1987 e Wang, 1990b) apesar de ser a mais tradicional (Bolstad e Lillesand, 1990) e o classificador Fuzzy permite a suavização destas saídas (Foody, 1995);
- combiná-la com outro classificador é uma abordagem prática e útil (Liu et al. 2002), visto que nenhum classificador é perfeito (Matsuyama, 1987).

Assim, a classificação Fuzzy é uma escolha óbvia para os mapeamentos da cobertura do solo abrangendo a sua heterogeneidade, resultante da ocorrência de pixels mistos e permite uma transição gradual entre as classes de cobertura do solo com a adesão dos pixels em qualquer parte do intervalo $[0, 1]$ (Islam, 2004).

Em se tratando da resolução espacial de sensores, a variabilidade dos dados diminui com a redução da resolução espacial. Inversamente, a variabilidade aumenta com a resolução espacial (Woodcock et al., 1988a, 1988b *apud* Islam, 2004), implicando na qualidade dos mapeamentos resultantes das classificações digitais.

Por fim, este trabalho contribuirá favoravelmente com a qualidade de mapeamentos da cobertura do solo aplicados aos planejamento de bacias hidrográficas, permitindo que seja avaliada a qualidade da classificação, fazendo uso de métodos adequados observando-se a resolução espacial do sensor escolhido.

1.4. Estrutura do trabalho

O primeiro capítulo deste trabalho contextualiza o tema proposto e apresenta os objetivos. No segundo capítulo encontram-se os fundamentos teóricos relacionados com o tema abordado na pesquisa. No terceiro capítulo, de materiais e método, são apresentadas as imagens utilizadas para a obtenção dos resultados, suas principais características, juntamente com os *softwares* utilizados; também, é descrita a metodologia desenvolvida.

No quarto capítulo são indicados os resultados obtidos, bem como os comentários cabíveis em cada situação e, por fim, no quinto capítulo são feitas as conclusões.

CAPÍTULO 2 - REVISÃO BIBLIOGRÁFICA

Este capítulo aborda os principais fundamentos teóricos necessários para a compreensão deste trabalho. Dividido em quatro partes, inicia-se contextualizando o Sensoriamento Remoto, bem como os seus alicerces e conceitos a respeito do comportamento de cada tipo de alvo terrestre em relação ao comportamento da energia refletida por eles. Em seguida, na segunda parte, considera os sensores orbitais utilizados, descrevendo suas principais características; na terceira foram abordadas as classificações digitais de imagens de sensoriamento remoto e, em especial, os métodos da Máxima Verossimilhança e Fuzzy. Na quarta parte deste capítulo de revisão, são apresentados parâmetros para a avaliação das classificações digitais como o Índice Kappa e a Matriz do Erro (ou da Correlação).

2.1 Sensoriamento Remoto

Segundo Lillesand e Kiefer (1994), a ciência que investiga a obtenção de informações sobre um objeto, área ou fenômeno natural sem a necessidade de estar em contato com estes é denominado Sensoriamento Remoto. Novo (2008) define sensoriamento remoto como sendo “a utilização conjunta de modernos sensores, equipamentos para processamento de dados, aeronaves, espaçonaves etc., com o objetivo de estudar o ambiente terrestre através do registro e das análises das interações entre a radiação eletromagnética e as substâncias componentes do planeta Terra em suas mais diversas manifestações”.

A radiação eletromagnética (REM) é subdividida em faixas, representando regiões que possuem características peculiares em termos dos processos físicos, geradores de energia em cada faixa, ou dos mecanismos físicos de detecção desta energia. Na Figura 2.1 é apresentado este Espectro Eletromagnético, que mostra o conjunto dos diferentes tipos de energia radiante conhecidos (Zeilhofer, 2000).




Figura 2.1 – Espectro eletromagnético.
Fonte: Zeilhofer (2000).

A radiação eletromagnética que é emitida pela fonte se propaga pela atmosfera até atingir os alvos da superfície terrestre. Todavia, sabendo-se que os principais constituintes atmosféricos responsáveis pela absorção de energia solar são O_3 (ozônio), O_2 (oxigênio), H_2O (água) e o CO_2 (gás carbônico) e que a radiação solar sofre interferência por eles, há prejuízo na qualidade e quantidade da energia solar disponível ao sensoriamento remoto (Lillesand et al, 2004).

A energia que, efetivamente, é emitida pela fonte e que incide sobre a superfície de um alvo pode ocasionar três tipos básicos de interações: reflexão, absorção e transmissão (Figura 2.2). A proporção desses mecanismos varia para diferentes alvos terrestres, dependendo do tipo e condição do material e do comprimento de onda da radiação incidente (Lillesand et al., 2004).

Após percorrer o trajeto da fonte até os alvos terrestres, a energia refletida e/ou emitida pela superfície é captada por dispositivos eletrônicos (sensores), instalados em satélites artificiais, e transformada em sinais elétricos, que são registrados e transmitidos para estações de recepção na Terra. Esses sinais recebidos pelas estações são transformados em dados na forma de gráficos, tabelas ou imagens, que, quando interpretados, permitem obter informações a respeito dos alvos da superfície terrestre (Florenzano, 2002).

A aquisição de dados de sensoriamento remoto, com aplicação em recursos naturais, tem sido feita através de diferentes tipos de sensores, desde a década de 1970,

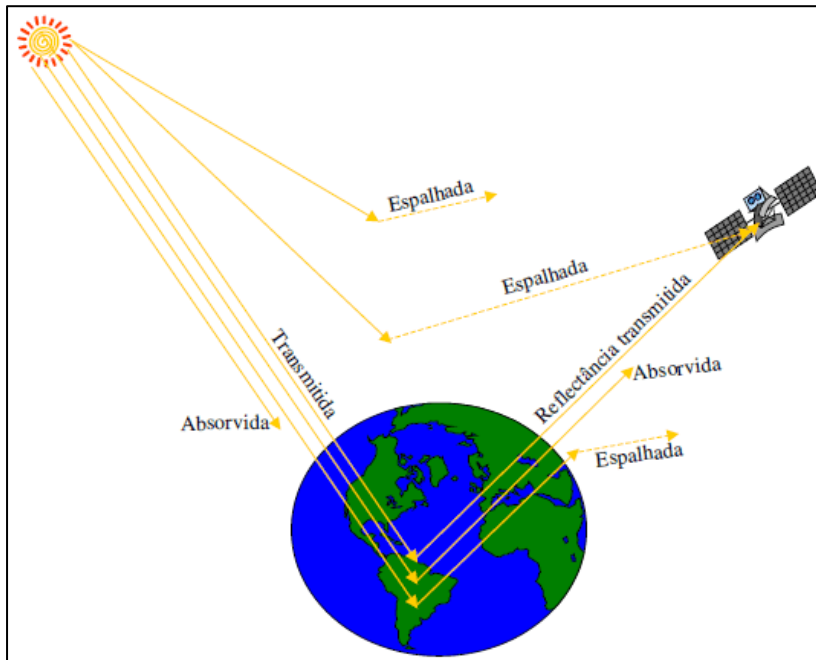


Figura 2.2 – Interações entre a energia eletromagnética e a superfície de um corpo.
 Fonte: Figueiredo (2006)

com o lançamento do primeiro satélite da série LANDSAT (caracterizado neste trabalho). Com o passar dos anos, muitos sistemas surgiram, cada qual voltado para finalidades específicas por possuírem características particulares (Prado, 2009).

2.1.1 Comportamento espectral dos alvos

O comportamento espectral de um objeto pode ser definido como sendo o conjunto dos valores sucessivos da reflectância do objeto ao longo do espectro eletromagnético, também conhecido como a assinatura espectral do objeto. Os objetos interagem de maneira diferenciada espectralmente com a energia eletromagnética incidente, pois os objetos apresentam diferentes propriedades físico-químicas e biológicas. Estas diferentes interações é que possibilitam a distinção e o reconhecimento dos diversos objetos terrestres sensoriados remotamente, pois são reconhecidos devido à variação da porcentagem de energia refletida em cada comprimento de onda. O conhecimento do comportamento espectral dos objetos terrestres é muito importante para a escolha da região do espectro sobre a qual se pretende adquirir dados para determinada aplicação (Moreira, 2001).

– *Solos*

Os parâmetros do solo que influenciam na radiação refletida pela superfície são diversos, porém, a literatura cita como os mais importantes os óxidos de ferro, a umidade, a matéria orgânica, a granulometria, a mineralogia da argila e o material de origem. Além desses fatores, têm sido citados: a cor do solo, a capacidade de troca catiônica, as condições de drenagem interna do solo, a temperatura, a localização, etc. Em determinadas condições, a influência de um parâmetro, na energia refletida pelo sol, inibe a dos outros, resultando, assim, num espectro característico deste parâmetro.

– *Óxidos de Ferro*

Os solos com considerável presença de óxidos de ferro apresentam influência em sua cor e, no contexto do sensoriamento remoto, a reflectância espectral dos solos pode ser usada como um critério importante na identificação dos tipos de solos que contêm diferentes concentrações do óxido. Solos com maiores quantidades de óxido de ferro absorvem energia eletromagnética na região do infravermelho próximo, de modo que, quanto maior o teor de óxido de ferro, maior a absorção de radiação eletromagnética. Tipos de solos como o Latossolo Ferrífero e os Latossolos Roxos refletem pouca energia eletromagnética, uma vez que possuem maiores teores de óxido de ferro quando comparados a outros tipos de solos.

– *Matéria Orgânica*

A composição e o conteúdo da matéria orgânica do solo são reconhecidamente fatores de forte influência sobre a reflectância dos solos (Numata et al., 2008). A elevada quantidade de matéria orgânica proporciona ao solo uma coloração escura, a qual tem como característica a intensa absorção de energia eletromagnética. A elevada temperatura em solos escuros durante o dia é atribuída a sua elevada absorção de energia solar, indicando que a reflectância é menor nestes casos. Sendo a matéria orgânica o constituinte primário da composição do solo, a sua presença ou ausência influi na reflectância (Dalmolin, 2002). Segundo Dalmolin (2002), inúmeros trabalhos quantificam a matéria orgânica e relaciona sua concentração a resposta espectral oferecida pela região que insere

esse tipo de solo, dentre eles: Al abbas et al. (1972), Demattê e Garcia (1999) que comprovaram experimentalmente que a resposta espectral aumenta quando há um decréscimo da matéria orgânica e que esta mascara propriedades que influenciam a reflectância espectral dos solos.

– *Umidade do solo*

A umidade presente no solo influencia a sua cor, tornando-o mais escuro e, portanto, absorvendo mais energia quando esta se incide culminando na reflectância diminuída (Dalmolin, 2002 e Moreira, 2001). É por este motivo que em um mesmo solo existem respostas espectrais diferentes, uma para cada estação ano, caracterizando-o mais seco ou mais úmido de acordo com a ocorrência de precipitação.

Várias curvas espectrais de solos contendo diferentes porcentagens de água são mostradas na Figura 2.3 (Moreira, 2001). A crosta superficial gerada por alguns fatores naturais faz com o comportamento de um tipo de solo tenha sua resposta espectral alterada. No caso dos solos úmidos, se houver a formação de crosta superficial, ele passa a se comportar como solo seco, aumentando os valores espectrais, fato comprovado nas primeiras pesquisas relativas a sensoriamento remoto onde no mesmo tipo de solo havia respostas espectrais diferentes. Algumas práticas agrícolas também são responsáveis pela alteração de resposta espectral de mesmo solo. A aeração forma torrões no solo, aumentando a rugosidade do mesmo e, além disso, esses torrões podem causar sombreamento, efeitos que contribuem para a alteração aqui comentada (Moreira, 2001).

– *Rugosidade e formação de crosta superficial*

Sabe-se que os solos possuem três frações que os caracterizam quanto à textura, sendo elas: areia, silte e argila, as quais se apresentam nos solos em diferentes tamanhos, mas pertencentes ao intervalo que as caracteriza. Dessa forma, um solo pode apresentar reflectância espectral diferente de outro solo da mesma classe devido ao tamanho e concentração destas partículas que compõem o solo. Moreira (2001) coloca que a estrutura dos solos pode ter influência na resposta espectral do mesmo que, aliada a textura do solo, determina a quantidade de espaços vazios, os quais podem ser ocupados por água ou ar. Também, podem existir minerais primários nos solos, os quais mudam suas características

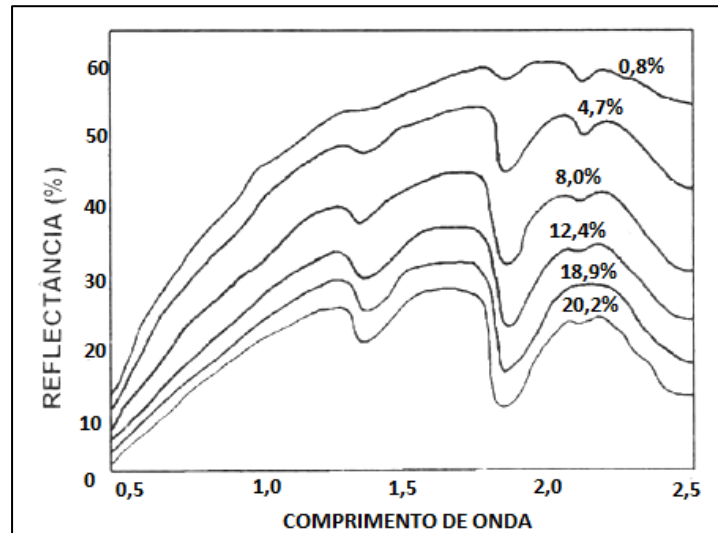


Figura 2.3 – Curvas espectrais de solos contendo diferentes porcentagens de água.
 Fonte: Moreira (2001)

espectrais. Pode-se concluir que a resposta espectral dos solos é resultante de inúmeras interações com água, ar, estrutura, textura e minerais, tornando-o um meio complexo quando o propósito é entender as frações energéticas que compõem suas características espectrais.

– *Vegetação*

As folhas são os elementos da vegetação que mais contribuem para o sinal detectado pelos sensores ópticos (Novo, 2008). A energia radiante interage com a estrutura foliar por absorção, espalhamento e transmissão. Uma folha típica é formada por três tecidos básicos: epiderme, mesófilo fotossintético e tecido vascular. O mesófilo é formado por células alongadas e de organização compacta (parênquima paliçádico), na parte superior e, na parte inferior, por células de formato irregular e sem arranjo definido (mesófilo esponjoso) além de espaços intercelulares onde ocorrem as trocas gasosas. As células do mesófilo são ricas em cloroplastos, onde se encontram os pigmentos. Os pigmentos das células do parênquima paliçádico têm um impacto significativo na absorção e reflectância da luz no visível enquanto que as células do parênquima esponjoso têm um impacto significativo na absorção e reflectância da energia incidente do infravermelho (Jensen, 2000).

Na Figura 2.4 pode-se reforçar ainda a influência da quantidade de água nas folhas, mostrando que a curva de reflectância das folhas, no infravermelho médio (1300 a 2500 nm), é inversamente proporcional à absorção de energia (Moreira, 2001).




Figura 2.4 – Influência da porcentagem de água na resposta espectral das folhas.
Fonte: Moreira (2001)

– Água

Na temperatura ambiente encontra-se água nos três estados físicos e, em cada um desses estados, a absorção da energia eletromagnética ocorre de maneira diferente (Novo, 2008 e Moreira, 2001) (Figura 2.5). Pode-se verificar que a água no estado líquido absorve mais energia refletindo quantidade inferior a 5 % da energia total incidente. Entretanto, é a forma física que mais absorve radiação em quase todos os comprimentos de onda. Na forma gasosa, a água apresenta reflectância em torno de 70 % e, na forma de sólida (gelo ou neve, por exemplo), apresenta a maior reflectância.

Inúmeros trabalhos tratam da qualidade de corpos d'água utilizando sensoriamento remoto, pois avaliam a resposta espectral desses corpos que varia de acordo com a quantidade dos materiais em suspensão, orgânicos ou inorgânicos. Na Figura 2.6 encontram-se resultados de estudos de reflectância em três corpos d'água com propriedades físico-químicas distintas: um reservatório (Barra Bonita), o Rio Piracicaba e o Rio Tietê, conforme estudo de Steffen et al. (1992). A reflectância das águas do Rio Tietê se

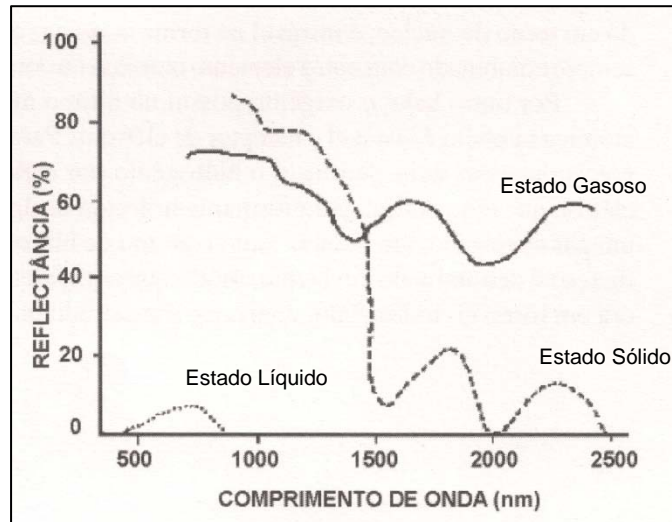


Figura 2.5 – Comportamento espectral da água nos seus três estados físicos.
 Fonte: Moreira (2001)

comporta como a reflectância de águas com elevada concentração de materiais inorgânicos, enquanto o Rio Piracicaba apresenta reflectância característica de corpos com alta concentração de material orgânico e, por sua vez, o reservatório de Barra Bonita apresenta características dos dois rios anteriores, pois se trata da transição entre os dois rios.




Figura 2.6 – Curvas de reflectância obtidas para o Rio Tietê, o Rio Piracicaba e para o reservatório de Barra Bonita, estudo de (Steffen et al., 1992).
 Fonte: Moreira (2001).

– Superfícies construídas

Conforme Novo (2008), os dois tipos de materiais predominantes nas superfícies construídas são concreto e asfalto. O concreto representa as áreas construídas nos seus

mais diversos tipos e o asfalto representa as áreas pavimentadas, sendo constituídos por estradas e rodovias, pátios, etc. As curvas espectrais do concreto e do asfalto são mostradas na Figura 2.7.

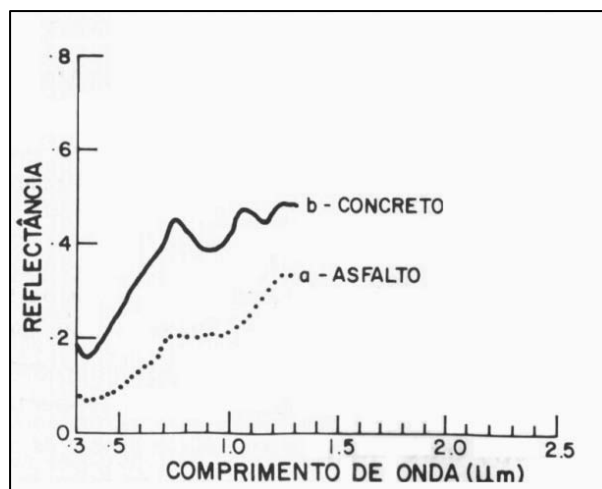


Figura 2.7 – Comportamento espectral do concreto e do asfalto.
Fonte: Novo (2008)

Pela análise da curva a, podemos verificar que o asfalto apresenta as seguintes características espectrais: a) reflectância baixa e decrescente entre 0,3 μm e 0,6 μm ($\rho < 0,1$); b) reflectância crescente entre 0,4 μm e 0,6 μm ($0,1 < \rho < 0,2$); c) reflectância de 0,2 entre 0,6 μm e 1,0 μm; d) reflectância crescente até 1,3 μm ($0,2 < \rho < 0,4$). Através da curva b, verificamos que o comportamento espectral do concreto é mais complexo, caracterizando-se por um aumento da reflectância com o comprimento de onda, mas apresentando feições amplas de absorção em 0,38 μm, entre 0,6 μm e 0,8 μm e em 1 μm (Novo, 2008).

2.2 Sistemas Sensores

Sensores são quaisquer tipos de equipamentos capazes de transformar alguma forma de energia em informação. Moreira (2001) define sensores como sendo equipamentos responsáveis pela coleta de informação, capazes de detectar e registrar a radiação emitida pelos alvos e gerar produtos em formato favorável a análises múltiplas, em funções dos seus objetivos.

Os sistemas sensores podem ser classificados de diversas maneiras. Quanto à forma de energia utilizada podem ser ativos, que produzem sua própria radiação (radares, por

exemplo), ou passivos, os quais necessitam de uma fonte de energia externa (sol) para emitir radiação possibilitando que esta seja refletida por alvos terrestre e captada por eles (Novo, 1992). Na Figura 2.8 encontram-se as classificações dos sistemas sensores quando à fonte de radiação, princípio de funcionamento e tipos de produtos.



Figura 2.8 – Classificação dos sistemas sensores quanto à fonte de radiação, ao princípio de funcionamento e aos tipos de produtos.
 Fonte: Moreira (2001).

Ainda em relação à classificação de sensores, Novo (2008) mostra que aqueles que operam na região óptica podem, ainda, ser classificados em função do tipo de energia que detectam, como os sensores termais e os sensores de energia refletida. Na Figura 2.9 são apresentadas as diferentes regiões do espectro ótico e os nomes pelas quais são conhecidas.

As imagens multiespectrais obtidas por sistemas sensores constituem um conjunto de cenas (denominadas canais ou bandas – Figura 2.10) adquiridas, simultaneamente, de uma mesma área, onde a REM é registrada em diferentes intervalos espectrais. Essas imagens são armazenadas como matrizes, onde cada elemento (denominado *pixel*) que as constitui possui coordenadas espaciais (x, y) e é representado por um conjunto de valores de brilho (tons de cinza ou níveis digitais). Assim, cada *pixel* pode ser representado por um vetor de atributos, cuja dimensão é definida pela quantidade de bandas espectrais

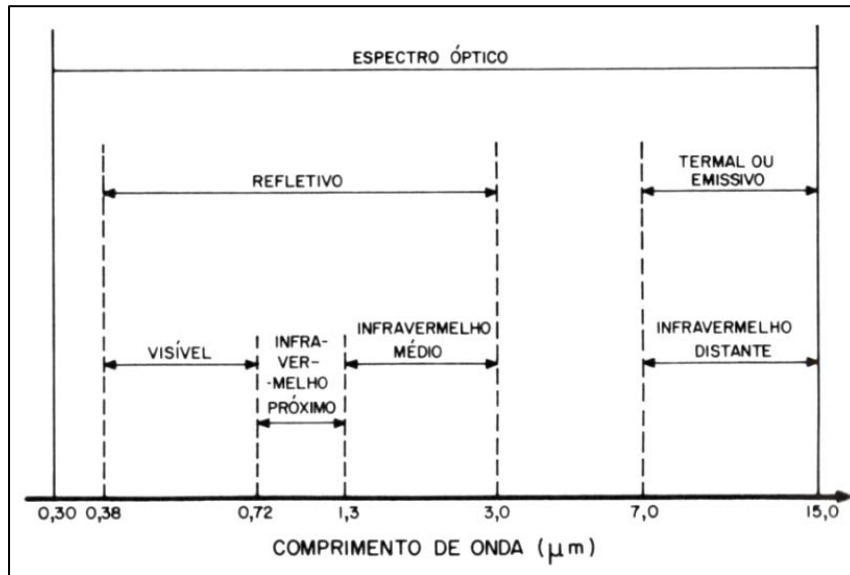


Figura 2.9 – Regiões do espectro óptico.
Fonte: Novo (2008)

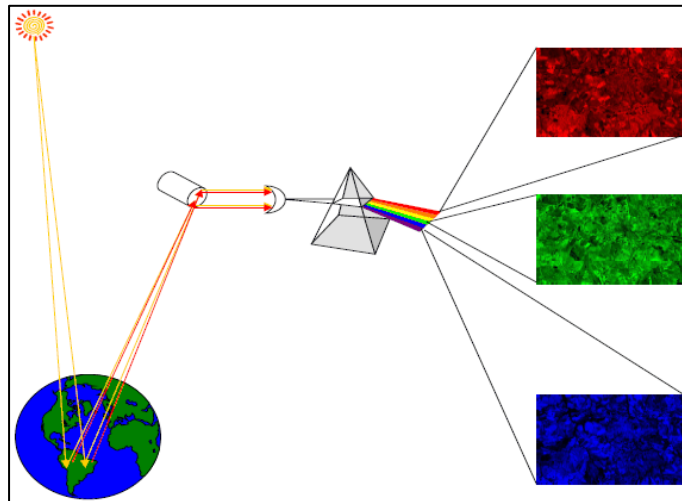


Figura 2.10 – Bandas espectrais

analisadas (Richards e Jia, 1999).

O tamanho do pixel que compõe uma imagem é responsável por definir a resolução de uma imagem que, é a característica do sensor que mede a habilidade em distinguir entre respostas que são semelhantes espectralmente ou próximos espacialmente, podendo ser ainda dividida em resolução espacial, espectral e radiométrica. Porém, Moreira (2001) e Souza et al. (2007) consideram ainda a resolução temporal.

2.2.1 Resolução

Os diferentes sistemas sensores são caracterizados por sua resolução, que é definida como a medida da habilidade que o sensor possui para discernir entre respostas espectralmente semelhantes e espacialmente próximas (Novo, 2008), sendo um dos fatores fundamentais no estabelecimento da legenda de mapas temáticos, pois interfere tanto na definição da área mínima a ser mapeada de um determinado tema, quanto na sua identificação. Tal importância tem sido sempre objeto de discussão e de atenção entre os usuários das técnicas de sensoriamento remoto e atualmente vem ganhando destaque devido ao desenvolvimento de sensores dotados de resolução espacial fina (da ordem de poucos metros) (Ponzoni e Shimabukuro, 2007).

Os sistemas de varredura dos satélites podem ser caracterizados pela *resolução espacial, espectral, radiométrica e temporal*:

- **Resolução espacial:** É o campo de visada instantânea (IFOV, do inglês, *Instantaneous Field of View*) que corresponde a menor área do terreno que um sistema sensor é capaz de individualizar (Souza et al., 2007).

- **Resolução espectral:** É a capacidade de discriminação dos materiais da superfície da terra e expressa a capacidade do sensor registrar a radiação em diferentes regiões do espectro. Portanto, quanto maior o número de canais espectrais, maior a capacidade discriminatória. A resolução espectral tem a ver com o número e os intervalos dos canais espectrais e é definida como a habilidade de separar coisas espectralmente semelhantes. Quanto maior a resolução espectral, maior as diferenças espectrais e melhor a separação dos alvos, apresentando a capacidade de discernir diferenças espectrais sutis (Brown et al., 2008).

- **Resolução radiométrica:** A resolução radiométrica corresponde à radiação eletromagnética refletida e/ou emitida pelos alvos da superfície terrestre, possui valor de intensidade que difere de um alvo para outro. Estes números representam uma média extraída da quantificação de reflectância recebida de uma porção da superfície terrestre (Moreira, 2001 e Souza et al., 2007).

- Para os satélites orbitais, consiste em indicar o intervalo de tempo que o satélite leva para recobrir a mesma área. Esta resolução é importante pelo fato de permitir uma análise temporal sobre os alvos da superfície da terra (Moreira, 2001).
- **Resolução Temporal:**

2.2.2 Sistemas Sensores Orbitais

Os sistemas de aquisição de dados de sensoriamento remoto, definidos como sistemas sensores, constituem-se de qualquer equipamento capaz de transformar a radiação eletromagnética refletida pelos alvos da superfície terrestre em um sinal passível de ser convertido em informações sobre o meio ambiente (Novo, 2008). Dentre a grande variedade de equipamentos que apresentam essa capacidade, podem ser destacados os sensores imageadores, os quais fornecem como produto uma imagem da cena observada.

Conforme descreve Novo (2008), os diferentes sistemas sensores são caracterizados pela sua resolução, definida como uma medida da habilidade que o sensor possui de distinguir entre respostas espectralmente semelhantes e espacialmente próximas. Além da resolução espacial, os sistemas de varredura instalados em satélites podem ser caracterizados em termos de sua resolução espectral, resolução radiométrica e resolução temporal.

A aquisição de dados de sensoriamento remoto, com aplicação em recursos naturais, pode ser feita por meio de sensores instalados em plataformas orbitais. Dentre os sistemas sensores atualmente em operação, pode-se destacar o TM – *Thematic Mapper* (instalado a bordo dos satélites LANDSAT 4 e 5); o AVNIR 2 – *Advanced Visible and Near Infrared Radiometer type 2*, que constitui carga útil do satélite ALOS e o CCD, câmera imageadora de alta resolução (Junqueira et. al., 2009) do satélite CBERS-2, cujas imagens foram utilizadas neste trabalho.

- *Thematic Mapper (TM) – LANDSAT-5*

O programa norte-americano LANDSAT é o programa de sensoriamento remoto mais conhecido e difundido em todo o mundo. Com início em 1972, marcado com o lançamento do LANDSAT-1, este programa tem como principal característica o grande acervo de imagens da superfície do globo terrestre. Apenas o satélite LANDSAT-5,

lançado em 1984 e operando até os dias atuais, já coletou mais de 700 mil imagens da Terra, segundo a United States Geological Service – USGS (2009). O último satélite da série foi lançado em 15 de abril de 1999 (LANDSAT-7) e operou normalmente até maio de 2003 (Rudorff et al., 2009) e, conforme Novo (2008), é o mais longo empreendimento em funcionamento para a aquisição de imagens da Terra do espaço.

Operando a bordo do satélite LANDSAT-5, o *Thematic Mapper* – TM constitui-se de um sensor imageador óptico multiespectral que coleta dados da superfície terrestre, simultaneamente, em sete bandas espectrais. Seis dessas bandas operam na região refletida do espectro óptico e apresentam uma resolução espacial de 30 metros no terreno. A outra banda espectral, designada como banda TM6, capta a radiação termal e tem uma resolução espacial de 120 metros. Na Tabela 2.1 são apresentadas as principais bandas espectrais do sensor TM, assim como os intervalos de comprimento de onda que as definem e suas principais aplicações.

Tabela 2.1 – Características do sensor TM – LANDSAT-5.

Características do sensor – TM (<i>Thematic Mapper</i>)	
Bandas espectrais	Banda 1 - Azul (0,450 - 0,520 μm)
	Banda 2 - Verde (0,520 - 0,600 μm)
	Banda 3 - Vermelho (0,630 - 0,690 μm)
	Banda 4 - Infravermelho próximo (0,760 - 0,900 μm)
	Banda 5 - Infravermelho médio (1,550 - 1,750 μm)
	Banda 6 - Infravermelho termal (10,40 - 12,50 μm)
	Banda 7 - Infravermelho médio (2,080 - 2,350 μm)
Resolução espacial	Bandas 1-5 e 7 – 30 metros
	Banda 6 – 80 metros
Largura da faixa imageada	185 km
Resolução temporal	16 dias

– *Charge Coupled Device (CCD) – CBERS-2*

O satélite CBERS-2 é resultado de uma parceria entre o Brasil e a China que construíram e lançaram os satélites de observação da Terra, CBERS-1 e CBERS-2 e CBERS-2B, CBERS-3 e CBERS-4. O programa CBERS teve início em julho de 1988 e foi projetado para cobertura global. Carrega câmeras para observação óptica e um sistema de coleta de dados ambientais.

Junqueira et al. (2009) descreve que a principal missão do programa CBERS é contribuir para o melhor entendimento do nosso planeta. Isso é conseguido pelo conjunto

de câmeras que continuamente imageiam a Terra em diferentes regiões óptico-espectrais e numa variedade de resoluções espaciais e temporais.

A carga útil do CBERS-2 consiste de uma Câmera Imageadora de Alta Resolução (CCD), um Radiômetro Imageador de Varredura no Infravermelho (IRMSS), uma Câmera Imageadora de Amplo Campo de Visada (WFI), um Monitor do Ambiente Espacial (SEM), e um Sistema de Coleta de Dados (DCS).

A câmera CCD é um sensor óptico capaz de adquirir imagens da Terra com resolução espacial de 20 metros. A resolução temporal oferecida pelo sensor é de 26 dias. Suas características tornam esta câmera um importante instrumento para fins de mapeamentos temáticos e tem sido usada para muitos projetos de pesquisa e operacionais no Brasil e na China, e mesmo em alguns países vizinhos para fins de pesquisa. Na Tabela 2.2 são apresentadas as principais peculiaridades do sensor CCD do satélite CBERS-2, conforme Moreira (2001).

Tabela 2.2 – Principais características do sensor CCD do satélite CBERS-2.

Bandas	Faixas Espectrais (nm)	Região do Espectro	Resolução Espacial (m x m)
1	450 – 520	Azul	20 x 20
2	520 – 590	Verde	
3	630 – 690	Vermelho	
4	770 – 890	IV Próximo	
5 (Pan)	510 – 730	VIS-IV Próximo	

Fonte: Moreira (2001)

Epiphanyo (2002) relaciona as principais aplicações deste sensor:

- Vegetação: identificação de áreas de florestas, alterações florestais em parques, reservas, florestas nativas ou implantadas, quantificações de áreas, sinais de queimadas recentes.
- Agricultura: identificação de campos agrícolas, quantificação de áreas, monitoramento do desenvolvimento e da expansão agrícola, quantificação de pivôs centrais, auxílio em previsão de safras, fiscalizações diversas.
- Meio ambiente: identificação de anomalias antrópicas ao longo de cursos d'água, reservatórios, florestas, cercanias urbanas, estradas; análise de eventos episódicos naturais compatíveis com a resolução da Câmera, mapeamento de cobertura do solo, expansões urbanas.
- Água: identificação de limites continente-água, estudos e gerenciamento costeiros, monitoramento de reservatórios.

- Cartografia: dada a sua característica de permitir visadas laterais de até 32° a leste e a oeste, em pequenos passos, possibilita a obtenção de pares estereoscópicos e a conseqüente análise cartográfica. Essa característica também permite a obtenção de imagens de certa área no terreno em intervalos mais curtos, o que é útil para efeitos de monitoramento de fenômenos dinâmicos.
- Geologia e solos: apoio a levantamentos de solos e geológicos.
- Educação: geração de material de apoio a atividades educacionais em geografia, meio ambiente, e outras disciplinas.

– *Advanced Visible and Near Infrared Radiometer Type 2 (AVNIR-2) – ALOS*

O satélite ALOS foi lançado em 24 de janeiro de 2006 pela Agência Espacial Japonesa (JAXA) para contribuir com os campos da cartografia (mapeamento, incluindo modelo digital de elevação), observação da cobertura do solo, monitoramento de desastres ambientais e levantamento de recursos naturais.

Os trabalhos com a utilização do satélite ALOS vem agora ganhando maiores proporções em decorrência do seu recente lançamento, porém ainda é encontrado um número reduzido de periódicos que o utilizem como fonte de dados.

A plataforma do satélite ALOS carrega três sensores (Figura 2.11):

- PRISM (*Panchromatic Remote-sensing Instrument for Stereo Mapping*), com 2,5 m de resolução espacial, e que compreende três sistemas ópticos possibilitando a formação de pares estereoscópicos para medição precisa das elevações;
- AVNIR – 2 (*Advanced Visible and Near Infrared Radiometer Type 2*), com resolução de 10 m, para observação da cobertura do solo;
- PALSAR (*Phased Array L-band Synthetic Aperture Radar*), com resolução de 10-100 m, para observação da Terra em qualquer condição atmosférica, de dia ou de noite, opera em microondas, já que é um radar de cobertura sintética.

O sensor AVNIR–2, cujos dados são usados neste trabalho, é um sistema óptico e oferece 4 bandas espectrais (visível e infravermelho próximo) com resolução espacial de 10 m, projetado para observação de regiões terrestres e costeiras. Suas imagens são úteis para o mapeamento da cobertura do solo para fins de monitoramento ambiental regional. Este sensor é capaz de variar a inclinação da visada lateralmente, tornando possível




Figura 2.11 – Estrutura e disposição dos sensores no satélite ALOS.
Fonte: JAXA (2008).

imagear rapidamente situações de desastres naturais (Gomes et al., 2007). Algumas de suas principais características são mostradas na Tabela 2.3.

Tabela 2.3 – Principais características do sensor AVNIR-2/ALOS.

Características do AVNIR-2	
Bandas Espectrais/comprimento de onda (microns)	1: 0,42 – 0,50
	2: 0,52 – 0,60
	3: 0,61 – 0,69
	4: 0,76 – 0,89
Resolução Espacial	10 metros (nadir)
Resolução Radiométrica	8 bits
Largura da faixa Imageada	70 km (nadir)
Número de detectores	7000/banda

Fonte: Sulsoft (2008).

Conforme Sulsoft (2008), para poder fazer uso adequado de todos os dados gerados por seus três sensores, o ALOS foi concebido seguindo dois eixos da alta tecnologia: grande capacidade de operação e velocidade de processamento e alta precisão de posicionamento e atitude do satélite, sendo fundamental nesta nova geração de satélites.

2.3 Classificação da cobertura do solo a partir de imagens de Sensoriamento Remoto

Inicialmente, antes de ser abordado o conceito de classificação, é pertinente que seja compreendido o conceito de uso e cobertura da terra. Prado (2009) considera que o termo “cobertura da terra” refere-se à cobertura (bio)física observada sobre a superfície terrestre, isto é, àquilo que se pode extrair diretamente de imagens orbitais ou fotografias aéreas. Essa definição é fundamental, visto que, em muitas classificações e legendas existentes,

nota-se uma confusão com a denominação “uso da terra”, que pode ser caracterizada pelas atividades desenvolvidas pelas pessoas que ocupam um tipo de cobertura da terra específico e interagem para mantê-lo ou modificá-lo (Di Gregório, 2004). Assim, por exemplo, as áreas de recreação existentes nas cidades são usos da terra que podem ser aplicados a diferentes tipos de cobertura da terra, desde áreas verdes até áreas construídas.

Prado (2009) também coloca que é importante destacar que o termo “terra” é definido no sentido de terra arável, o mesmo que solo agriculturável ou solo e que, em alguns casos, os termos “terra” e “solo” não são considerados sinônimos.

2.3.1 Classificação de imagens

Um sistema de classificação consiste em uma estrutura de representação de classes temáticas em níveis de detalhamento (Prado, 2009). Para que um sistema de classificação possa ser utilizado como referência, Di Gregório (2004) enfatiza que este deve ter as seguintes características:

- amplo e consistente cientificamente;
- capaz de suprir a necessidade de uma variedade de usuários;
- potencialmente aplicável como um sistema de referência comum e que facilita comparações entre classes derivadas de diferentes classificações;
- flexível, podendo ser usado em diferentes escalas e em diferentes níveis de detalhe, permitindo confrontar mapas globais, continentais, regionais e locais sem perda de informação;
- capaz de descrever a diversidade de características da cobertura da terra, com claras definições dos limites das classes; e
- baseado numa descrição clara e sistemática das classes, onde os critérios usados para defini-las não devem ser ambíguos.

Um sistema de classificação adequado deve ser independente da escala, ou seja, as classes devem ser aplicáveis em qualquer escala ou nível de detalhe e independente da fonte, isto é, independente dos meios usados para coletar a informação, quer seja através de imagens de satélite, fotografias aéreas, levantamentos de campo ou usando uma combinação de fontes (Di Gregório, 2004).

Jensen (1996) afirma que a classificação é uma das técnicas mais frequentes usadas para a extração de informações de dados de sensoriamento remoto e que implica no

reconhecimento de padrões e feições homogêneas em uma imagem. A discriminação e o posterior reconhecimento desses padrões é possível devido aos diferentes alvos da superfície terrestre apresentarem um comportamento espectral específico (Schowengerdt, 2007).

Prado (2009) ainda coloca duas abordagens que geralmente são utilizadas para realizar o processo de classificação. A primeira, análise visual, envolve uma interação direta entre o analista e os dados representados na imagem, e é bastante efetiva na avaliação dos aspectos globais de uma cena e na definição dos tipos de classes. Por outro lado, quando se trata da utilização de computadores para avaliar automaticamente a natureza multiespectral de uma imagem, são empregadas técnicas de análise digital (RICHARDS; JIA, 1999), as quais tendem a tornar o processo de mapeamento menos subjetivo e com maior potencial de repetição em situações subseqüentes (NOVO, 2008).

Muitas vezes, a análise visual de imagens é feita no próprio computador, onde são considerados os diferentes elementos de interpretação de imagens (tonalidade, padrão, forma, tamanho, textura, sombra, associação e localização) e selecionada a composição colorida que melhor permita a identificação das classes de interesse (Prado, 2009).

A classificação de imagens é o processo utilizado para produzir mapas temáticos (Schowengerdt, 2007). Para atingir essa finalidade deve-se prever, inicialmente, segundo Prado (2009), a definição de um sistema de classificação que seja adequado ao estudo que se pretende desenvolver. Esse sistema deve especificar claramente as classes de informação que constarão no mapeamento temático e os critérios usados para distingui-las. Assim, classificar envolve, necessariamente, a definição dos limites das classes, os quais devem ser claros, possivelmente quantitativos e baseados em critérios objetivos (Di Gregório, 2004).

As técnicas de classificação são normalmente baseadas em duas abordagens (Richards e Jia, 1999). A primeira é denominada classificação supervisionada e implica na interação do analista e o sistema de análise com base em um conhecimento prévio da cena, o qual o habilitará a fornecer informações específicas e treinar o algoritmo de classificação (Gonzalez e Woods, 2000). Assim, um conjunto de dados de treinamento contendo exemplos de padrões de todas as classes temáticas existentes no sistema é usado pelo classificador para tomar decisões, bem como para calcular estatísticas descritivas (por exemplo, média e variância) para cada classe (Zhang e Foody, 2001).

A outra abordagem é chamada de classificação não-supervisionada, onde os elementos de uma imagem são associados a classes espectrais sem que haja um

conhecimento prévio da existência ou do nome dessas classes. A estratificação da cena é definida sem a interferência do analista na atribuição de cada elemento da imagem a uma determinada classe espectral. Normalmente, as classes espectrais são definidas com base no agrupamento de pixels que apresentam similaridade espectral através da aplicação de métodos de agregamento, utilizando medidas de similaridade (ex.: distância Euclidiana) (Richards e Jia, 1999). Nesse caso, a vantagem consiste exatamente na não exigência de nenhum conhecimento a priori da área de estudo, confiando apenas na estrutura espectral interna do conjunto de dados.

Considerando o elemento de análise, os classificadores podem ser divididos em: por pixel e por regiões. Os classificadores por pixel utilizam apenas a informação espectral, isoladamente de cada *pixel*, para encontrar a classe mais provável para o pixel. Por outro lado, os classificadores por regiões agrupam pixels vizinhos com características similares e depois classificam esses agrupamentos (regiões) considerando os atributos espectrais da região e os parâmetros espaciais que podem ser derivados da distribuição espacial dos *pixels* que formam a região (Venturieri e Santos, 1998).

2.3.2 Classificação pelo método da Máxima Verossimilhança (MAXVER)

Segundo Richards e Jia (1999), o método de Máxima Verossimilhança é o mais utilizado na classificação supervisionada de dados de Sensoriamento Remoto. Contribuiu para a sua popularidade seu satisfatório desempenho, fato que justifica a comparação de muitas novas técnicas descobertas a esse método (Bolstad e Lillesand, 1990).

Trata-se de um classificador paramétrico, que assume distribuição de probabilidade normal para cada uma das classes, através da qual estima os parâmetros vetor média e matriz de covariância, e computa as probabilidades de um pixel pertencer a cada uma das classes cujos parâmetros são assumidos na fase de treinamento, associando-o à classe a qual ele apresenta maior probabilidade (Jensen, 1996).

Segundo Jensen (1996), um pixel se enquadra, de acordo com a Máxima Verossimilhança, na categoria de uso do solo predominante na sua composição. Considera a ponderação das distâncias das médias e utiliza parâmetros estatísticos para efetuar a classificação, partindo do princípio que o usuário já tem um conhecimento prévio da imagem a ser classificada para poder definir as classes representativas.

O método da Máxima Verossimilhança avalia a covariância e a variância da categoria da resposta espectral quando é classificado um pixel desconhecido. Para tanto, é usada a distribuição Gaussiana (distribuição normal). Esta suposição de distribuição normal é geralmente razoável de para distribuições de respostas espectrais comuns e, além disso, trata-se de uma distribuição que pode ser completamente descrita pelo vetor médio da classe e matriz de covariância dessa mesma classe. Através destes parâmetros, pode-se calcular a probabilidade estatística de um dado pixel de pertencer a uma determinada categoria (Lillesand e Kiefer, 1994).

Na Figura 2.12 são apresentados, em três dimensões, exemplos de probabilidades. No eixo vertical encontra-se a probabilidade do pixel pertencer a uma dada classe. O resultado gera uma superfície com presença de “sinos”, chamados funções de densidade de probabilidade, encontrando-se uma para cada categoria espectral definida. As funções densidade de probabilidade são usadas para classificar um pixel indefinido calculando a probabilidade de um pixel pertencer a cada categoria. Em relação à Figura 2.12, pode-se encontrar a probabilidade de um determinado pixel pertencer à categoria milho, à categoria floresta e nas demais.




Figura 2.12 – Função densidade de probabilidade definida no método da Máxima Verossimilhança.
Fonte: Lillesand e Kieffer (1994).

Matematicamente, o classificador MAXVER define a classe mais provável a que um pixel possa pertencer. Sendo \vec{x} o valor do vetor de atributo, neste momento, é necessário que a classe mais provável (ω_j) seja definida, dentro de um conjunto infinito de classes possíveis: $W = \omega_1, \omega_2, \omega_3, \dots, \omega_m$. Na forma de probabilidade condicional, pode

ser escrito por $p(\omega_j | \vec{x})$. Segundo Richards e Jia (1999), dada uma classe $\omega_j =$ vegetação, a probabilidade de se encontrar pixels com alto valor no infravermelho próximo é alta, porém, ao se considerar uma classe $\omega_j =$ água, essa probabilidade é muito pequena.

A probabilidade de um pixel ocorrer em uma imagem, $p(\vec{x})$, é dada por:

$$p(\vec{x}) = \sum_{j=1}^m p(\vec{x} | \omega_j) \cdot p(\omega_j) \quad (1)$$

E a probabilidade de ocorrência concomitantemente dos eventos $p(\vec{x})$ e (ω_j) é uma probabilidade conjunta definida por:

$$p(\omega_j, \vec{x}) = p(\omega_j | \vec{x}) \cdot p(\vec{x}) \quad (2)$$

equivalente a:

$$p(\vec{x}, \omega_j) = p(\vec{x} | \omega_j) \cdot p(\omega_j) \quad (3)$$

Por isso, igualando-se a equação 2 com a equação 3, encontra-se a expressão para a probabilidade condicional, conhecida como Teorema de Bayes (Richards e Jia, 1999), dada por:

$$p(\omega_j, \vec{x}) = \frac{p(\vec{x}, \omega_j) \cdot p(\omega_j)}{p(\vec{x})} \quad (4)$$

sendo:

- $p(\omega_j)$ a probabilidade da classe ω_j ocorrer na imagem;
- $p(\vec{x})$ a probabilidade de se encontrar um pixel \vec{x} na imagem.

A classificação é decidida conforme a seguinte regra:

$$\vec{x} \in \omega_j \text{ se } p(\omega_j, \vec{x}) > p(\vec{x}, \omega_j), \text{ para todo } j \neq i. \quad (5)$$

Conforme Richards e Jia (1999), as probabilidades definidas até agora não são conhecidas. Contudo, se dados de treinamento estão disponíveis para cada classe, pode-se estimar uma distribuição de probabilidades que descreve a chance de encontrar um pixel \vec{x} na classe ω_j , descrito por $p(\vec{x}, \omega_j)$, independente da sua distribuição.

As probabilidades $p(\omega_j, \vec{x})$ são denominadas probabilidades “a posteriori” e $p(\omega_j)$ como probabilidades “a priori”. Substituindo-se a equação 4 na equação 5 entra-se nova regra de decisão:

$$\vec{x} \in \omega_j \text{ se } p(\vec{x} | \omega_j) \cdot p(\omega_j) > p(\vec{x}, \omega_j) \cdot p(\omega_j), \text{ para todo } j \neq i \quad (6)$$

Portanto, a expressão mais utilizada para expressar a função de decisão de Máxima Verossimilhança é:

$$g_j(\vec{x}) = \ln\{p(\vec{x} | \omega_j) \cdot p(\omega_j)\} \quad (7)$$

equivalente a:

$$g_j(\vec{x}) = \ln p(\vec{x} | \omega_j) + \ln p(\omega_j) \quad (8)$$

Assim, a regra de classificação generalizada usada na classificação pelo método da Máxima Verossimilhança é dada por:

$$\vec{x} \in \omega_j \text{ se } g_j(\vec{x}) > g_i(\vec{x}), \text{ para quaisquer } j \neq i. \text{----- (9)}$$

2.3.3 Classificação Fuzzy

A teoria Fuzzy (ou dos conjuntos nebulosos) é uma alternativa para o raciocínio imprecisos introduzida em 1965 por Lotfi Zadeh (Zadeh, 1965), em situações onde não cabe a interpretação booleana ou o tratamento de falso/verdadeiro, sim/não, certo/errado (Lima Jr., 2002). As vantagens são inúmeras, aumentando a probabilidade de se articular eficientemente soluções para problemas complexos, tornando-se uma forma de caracterizar classes de uso da terra que, por diversas razões, não possuem limites rígidos entre si (Moreira, 2002).

A Figura 2.13 ilustra a indefinição de fronteiras ou limiares entre as classes ao considerar um conjunto nebuloso (ou Fuzzy) em comparação com um conjunto booleano (Câmara et al., 2005). As análises baseadas em conjuntos Fuzzy se diferenciam das análises *booleanas* que normalmente estão disponíveis na maior parte dos aplicativos SIG, sendo necessárias implementações. Conforme Burrough e Heuvelink (1992 apud Moreira, 2002), os métodos *booleanos* estão muito mais sujeitos à propagação de erros em modelagens do que os equivalentes Fuzzy, e a utilização da técnica nebulosa pode reduzir drasticamente a propagação de erros através de modelos lógicos, fornecendo cenários mais confiáveis.




Figura 2.13 – Fronteiras entre um conjunto Fuzzy (A) e um conjunto booleano (B).
Fonte: Câmara et al.(2005).

Os sistemas Fuzzy foram desenvolvidos para diversas áreas do conhecimento, como controladores de operações automáticas, aplicações industriais, reconhecimento de padrões, imagens e áudio, análises quantitativas, processos cooperativos, sistemas para recuperação de informações e, notadamente, sistemas especialistas (Pedrycz e Gomide, 2008; Teodorescu et al., 1999).

A teoria dos conjuntos Fuzzy pode ser caracterizada por uma função de pertinência, que mapeia os elementos de um espaço para um número real $[0, 1]$. Assim, um conjunto Fuzzy apresenta-se como um conjunto de pares ordenados, em que o primeiro número é o elemento do espaço e o segundo é o seu grau de pertinência no domínio (Zadeh, 1969). A função de pertinência é o componente crucial de um conjunto Fuzzy, e muitas operações são definidas em conformidade com a mesma (Zadeh, 1965). Uma vez identificados objetos ou conjuntos Fuzzy, a primeira tarefa a cumprir é descobrir a melhor forma de determinar a função de pertinência (Inuiguchi et al., 2000; Arslan e Kaya, 2001).

Em classificações de imagens multiespectrais, normalmente, a informação é extraída por meio de técnicas de classificação convencionais, as quais são baseadas na lógica booleana e o pixel é atribuído a uma única classe de cobertura do solo, desconsiderando a existência, em qualquer proporção, de contribuição de outras classes para esse pixel. Essas técnicas de representação têm dificuldades em lidar com fenômenos que não podem ser descritos por uma pertinência total em um único conjunto (Wang, 1990a).

A proporção de pixels mistos em uma imagem irá variar com inúmeros fatores, principalmente com o mosaico de cobertura do solo ao redor e com a resolução espacial do sensor. Esta proporção aumenta, geralmente, com a diminuição da resolução espacial usada em mapeamentos nas escalas regional e global, onde talvez o sensoriamento remoto orbital seja a principal fonte de dados para mapeamentos temáticos, com grandes quantidades de por pixels mistos (Foody, 1997).

Das várias maneiras de derivar uma classificação Fuzzy, destaca-se a relativa bayesiana. Nela são consideradas a média e a matriz de variância e covariância ponderadas, cujos pesos são graus de pertinência Fuzzy estimados a partir de dados de treinamento para as classes (Eastman e Laney, 2002).

As classes de informação, ao serem representadas como conjuntos Fuzzy, o espaço espectral não é dividido por superfícies rígidas, gerando uma classificação Fuzzy. Assim, graus de pertinência são atribuídos aos pixels para indicar a extensão com que estes pertencem a cada classe. A suposição básica da abordagem Fuzzy é que os graus de pertinência são informativos sobre os componentes sub-pixel (Fisher e Pathirana, 1990 e Foody, 1994). Tal partição é chamada de partição Fuzzy do espaço espectral, conforme Wang (1990a).

Embora o conceito de classificação Fuzzy não seja novo, a aplicação apropriada da técnica e, particularmente, a definição de funções de pertinência Fuzzy adequadas não são

triviais. As funções de pertinência devem ser definidas de acordo com a natureza do fenômeno sob estudo, os objetivos da classificação e os métodos de aquisição de dados específicos (Zhang e Stuart, 2001).

As classes em um modelo Fuzzy podem ser de dois tipos: classes discretas, cujos membros apresentam uma pertinência total (ou completa) para uma das categorias de referência; e classes contínuas, nas quais a pertinência de um indivíduo em relação a cada classe é parcial (entre zero e 1) (Leguizamón et al., 1996). As classes contínuas são uma generalização do caso discreto, onde o indicador da função que, na teoria dos conjuntos convencional aponta para 1 ou 0, é substituído pela abordagem de conjuntos Fuzzy, na qual os valores calculados estão entre 0 e 1.

Existem várias maneiras de derivar uma classificação Fuzzy. Uma classificação Fuzzy pode, por exemplo, ser derivada a partir do classificador de Máxima Verossimilhança, conservando as probabilidades de pertinência de pixels individuais pertencentes a todas as classes candidatas (Foody et al., 1992; Wang, 1990b). Este tipo de classificação também pode ser derivado de uma gama de outras abordagens disponíveis. Por exemplo, quando uma rede neural artificial é usada para classificação, a força de pertinência de classe pode ser medida pelo nível de ativação dos nós de saída da rede (Foschi e Smith, 1997 *apud* Zhang e Foody, 2001).

Classificações Fuzzy podem também ser derivadas usando técnicas como agrupamento Fuzzy *c*-médias (Bezdek et al., 1984); modelagem de mistura linear (Settle e Drake, 1993) e redes neurais artificiais (Foody, 1996). A classificação baseada em abordagem Fuzzy tem sido aplicada tanto para lidar com a incerteza em mapeamento de cobertura da terra (Canters, 1997; Fisher e Pathirana, 1990) quanto para avaliar a acurácia de mapas classificados (Gopal e Woodcock, 1994; Laba et al., 2002). Cheng et al. (2001) relatam esforços para derivar limites Fuzzy para objetos a serem armazenados dentro de um SIG (Sistema de Informação Geográfica) e Wang e Hall (1996) discutem o uso de métodos Fuzzy na representação de incerteza de limites entre classes de diferentes naturezas.

Matematicamente, a classificação estaria mais simplificada podendo se utilizar a seguinte regra:

$$x \in \pi_i \text{ se } (x_0 - \bar{x}_i)'(x_0 - \bar{x}_i) < (x_0 - \bar{x}_j)'(x_0 - \bar{x}_j) \forall j \neq i \text{ onde } i, j = 1, 2, 3, \dots, m. \quad (10)$$

ou

$$x \in \pi_i \text{ se } d(x_0, \bar{x}_i)^2 < d(x_0, \bar{x}_j)^2 \forall j \neq i \text{ onde } i, j = 1, 2, 3, \dots, m. \quad (11)$$

A classificação de um novo pixel pelo método de Distância Mínima é obtida a partir da menor distância entre o pixel a ser classificado (x_0) e os valores médios obtidos das amostras treinadas (\bar{x}_1, \bar{x}_2 e \bar{x}_3).

Matematicamente, para se desenvolver o critério que rege o classificador Fuzzy utilizando o algoritmo da Mínima Distância da Média, supõe-se que $\bar{m}_j, j = 1, 2, 3, \dots, M$, sejam as médias das M classes, determinadas a partir dos dados de treinamento, e \vec{x} seja o vetor do pixel a ser classificado (Richards e Jia, 1999). Dessa forma, a regra de decisão, a partir do conjunto de Distâncias Euclidianas, fica sendo como:

$$\vec{x} \in \omega_j \text{ se } d(\vec{x}, \bar{m}_j)^2 < d(\vec{x}, \bar{m}_i)^2, \text{ para quaisquer } j \neq i. \text{-----} (12)$$

Como $\vec{x} \cdot \vec{x}$ é comum dos dois lados da expressão vetorial anterior, é removido resultando na expressão final para a Distância Mínima da Média:

$$\vec{x} \in \omega_j \text{ se } g_j(\vec{x}) > g_i(\vec{x}) \text{ para quaisquer } j \neq i \text{-----} (13)$$

onde:

$$g_j(\vec{x}) = 2\bar{m}_j \cdot \vec{x} - \bar{m}_j \cdot \bar{m}_j \text{-----} (14)$$

Ao se considerar o critério da Distância Mínima da Média na classificação Fuzzy, calcula-se a pertinência de conjunto Fuzzy baseada na distância Euclidiana da média das assinaturas espectrais de cada classe, usando uma função de pertinência sigmoideal. Quando a distância da média aumenta, o valor assumido pela função de pertinência diminui, até alcançar um limiar definido pelo usuário, o qual depende da quantidade de classes temáticas definidas para a classificação e da largura das classes (Eastman, 2006).

2.4 Reconhecimento do grau de incerteza

Em sensoriamento remoto o termo “acurácia” é normalmente empregado para expressar o grau de acerto de uma classificação (Foody, 2001). Portanto, acurácia na classificação é entendida como o grau para o qual a classificação derivada da imagem concorda com a realidade ou está em conformidade com a verdade terrestre (Campbell,

1996; Janssen e Van der Well, 1994 *apud* Foody, 2001). O erro da classificação é, portanto, uma discrepância entre a situação retratada no mapa e a realidade (Foody, 2001).

Assim, após o processo de classificação, torna-se necessária a avaliação da exatidão da classificação, ou seja, é necessário se determinar quão bom é o resultado da classificação em relação à realidade. O método de avaliação da classificação depende da disponibilidade de dados em campo (Novo, 2008). Parâmetros que possibilitem a quantificação da exatidão do levantamento de uso das terras são essenciais (Foody, 2009).

A forma mais utilizada para representar a exatidão de classificação é a comparação do mapa derivado da imagem com o mapa de referência a partir da utilização de uma matriz de erro, também conhecida como matriz de confusão, matriz de correlação ou tabela de contingência (Fidalgo, 1995). A diagonal da matriz representa a coincidência entre os dados classificados e os dados reais (Novo, 2008).

A matriz do erro oferece o coeficiente Kappa, um dos mais utilizados e eficientes na determinação da exatidão, o qual é obtido mediante a adoção de uma referência para a comparação dos mapeamentos produzidos (Congalton e Green, 1993; Cohen, 1960). Matematicamente, é expresso pela seguinte expressão:

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

onde:

- N é o número total de pixels contemplado pela matriz de erro;
- x é o elemento da matriz de erro;
- r é o número de categorias presentes na matriz de erro;
- x_{ii} são os elementos da diagonal principal.

Os resultados da estatística Kappa normalmente são comparados aos valores contidos na Tabela 2.3, proposta por Landis & Koch (1977), a fim de indicar a qualidade do mapa temático. Embora essa tabela tenha sido desenvolvida para analisar diagnósticos clínicos, a mesma tem sido referência para classificar mapas resultantes da utilização de imagens de sensoriamento remoto, dentro de certas restrições (Prado, 2009).

O coeficiente Kappa pode variar de -1 a 1, indicando a qualidade da classificação realizada. Rosenfield e Litzpatrick-Lins (1986) também associam os valores obtidos para este coeficiente a qualidade da classificação, assim como nos trabalhos desenvolvidos por

Tabela 2.4 – Qualidade do mapeamento temático associada aos valores da estatística Kappa.

Valor de Kappa	Qualidade do mapa
< 0,00	Péssima
0,00 – 0,20	Ruim
0,20 – 0,40	Razoável
0,40 – 0,60	Boa
0,60 – 0,80	Muito boa
0,80 – 1,00	Excelente

Fonte: Landis & Koch (1977)

Korman (2003), Pinho et al. (2007), Ferreira et al. (2007), Rodrigues et al. (2007).

Campbel (1987), Foody (1992) e Masseli et al. (1994) afirmam que o problema fundamental na verificação da acurácia de classificações utilizando Fuzzy através de matrizes é que elas devem ser empregadas quando a saída dos dados é rígida. Assim, é necessário que os resultados desta classificação sejam transformados em dados rígidos para tal utilização.

CAPÍTULO 3 - MATERIAIS E MÉTODO

Neste capítulo são apresentados os dados utilizados e suas respectivas fontes, assim como o procedimento realizado para o cumprimento dos objetivos.

3.1 Materiais

Foram utilizadas imagens de sensoriamento remoto em três resoluções espaciais distintas para a obtenção de mapas de cobertura do solo e fotografias aéreas coloridas verticais (em formato digital) que serviram de insumo para a confecção dos mapas de verdade terrestre. Os aplicativos utilizados foram o SIG Idrisi, versão Andes, para o tratamento dos dados de sensoriamento remoto e classificações digitais, *Corel Draw* para o tratamento das imagens resultantes do processo de classificação, AutoCAD, versão 2008, para a digitalização dos temas nas fotografias aéreas coloridas e, da *Microsoft Corporation*, o Excel 2007, para tratamento quantitativo dos resultados (Quadro 3.1).

Quadro 3.1 - Características das imagens de sensoriamento remoto, fotografias aéreas e aplicativos.

IMAGENS						APLICATIVOS
Fonte	Sensor	Tomada das imagens	Resolução espacial	Banda	Intervalo espectral (mícron)	
Satélite ALOS	AVNIR-2	12/11/2006	10 m	1	0,42 – 0,50	Idrisi versão Andes (15.0) CorelDraw versão 13 AutoCAD versão 2008 Excel 2007 (Microsoft Corporation)
				3	0,61 – 0,69	
				4	0,76 – 0,89	
Satélite CBERS-2	CCD	19/07/2007	20 m	2	0,45 – 0,52	
				3	0,52 – 0,59	
Satélite LANDSAT-5	TM	22/07/2007	30 m	4	0,63 – 0,69	
				2	0,52 – 0,60	
				3	0,63 – 0,69	
Fotografias Aéreas Coloridas	-	13/05/2007	2,80 m	4	0,76 – 0,90	
				-	-	

3.2 Localização da área de estudo

A área de estudo deste trabalho está incluída no município de São Carlos, localizado, na região central do estado de São Paulo, como mostra a Figura 3.1. Localiza-se entre as coordenadas 48°09'20.24" – 21°32'14.25" (canto superior esquerdo) e 47°38'56.97"–22°20'53.23" (canto inferior direito).

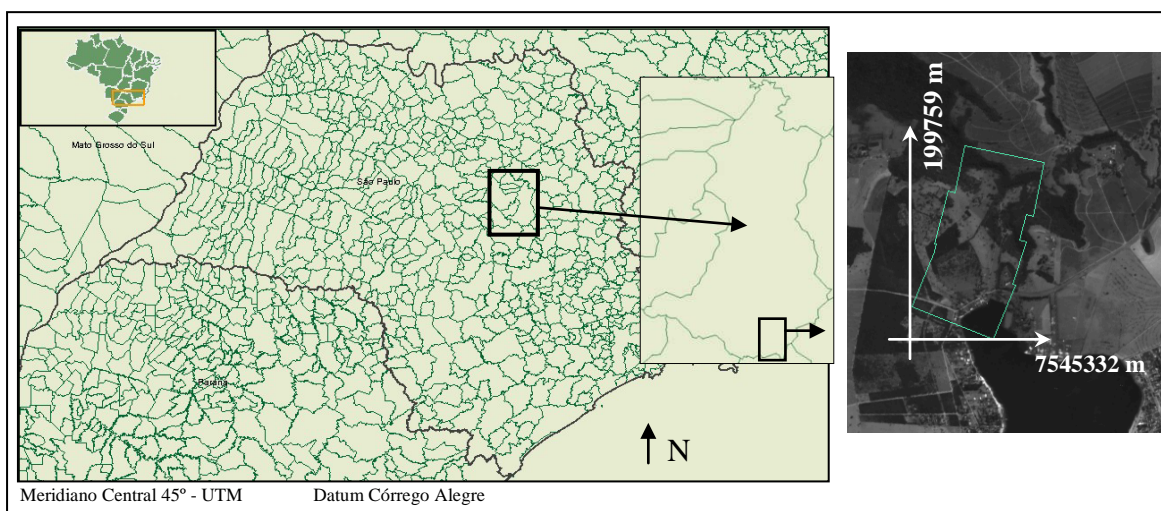


Figura 3.1 – Localização da área de estudo no município de São Carlos, SP. Recorte de área inserido no limite da bacia hidrográfica do córrego do Feijão e na bacia hidrográfica do Jacaré-Guaçu.

São Carlos tem uma área total do município de 1.143,9 Km² e uma área urbana próxima de 102,99 Km² (em 1998). Sua população atual está estimada pelo em 212.956 habitantes (IBGE, 2008). Na Figura 3.2 encontra-se a bacia hidrográfica de São Carlos composta por outras 9 sub-bacias e nela é destacado o trecho escolhido para estudo, a ser caracterizado no item 4.1 deste trabalho.

Tundisi et al. (2005) afirma que o município de São Carlos está localizado na Província Geomorfológica das Cuestas Basálticas onde, no passado, havia predomínio da vegetação Cerrado e Floresta Estacional Semidecídua, existindo atualmente apenas os remanescentes destes ecossistemas, que sofrem grande pressão das atividades agrícolas de produtores de cana-de-açúcar e laranja, culturas com grande expressão na região. Apesar da dominação de capital nacional da tecnologia, as diferenças sociais são marcantes e são representadas por “bolsões” de pobreza em vários pontos da área urbana.

Segundo Nishiyama (1991), a vegetação primitiva local era representada pelos campos de cerrados, cerrados e cerradões, condicionada pela predominância de solos muito profundos, excessivamente ou muito permeáveis e de baixo potencial nutricional. Essa vegetação normalmente é constituída de uma cobertura herbácea mais ou menos contínua e

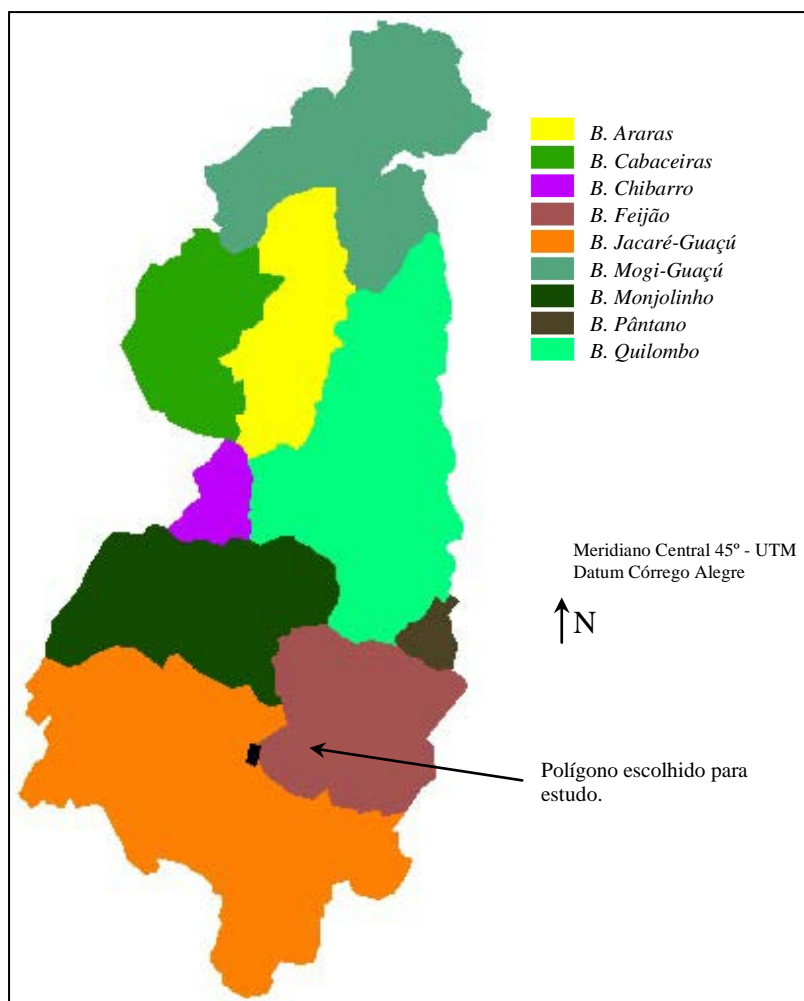


Figura 3.2 – Sub-bacias que compõem a bacia hidrográfica do município de São Carlos/SP.
 Fonte: Tundisi et al. (2007)

um dossel descontínuo de elementos arbóreos e arbustivos. A temperatura média anual está próxima de 19,5°C, sendo que a máxima média mensal encontra-se nos meses de janeiro e fevereiro com 21,9°C e a mínima média mensal ocorre no mês de julho, com 15,9°C.

A geologia é representada por afloramentos das formações geológicas Pirambóia, Botucatu, Serra Geral, Bauru e mais os sedimentos cenozóicos. A Formação Pirambóia – ocorre somente numa pequena parte do lado oeste. Ela se apresenta como um arenito de granulometria fina a média de coloração amarela e com predominância de finos. A profundidade varia entre 1 a 5 metros (Zuquette, 1981).

3.3 Método

Na Figura 3.3 encontra-se o fluxograma que resume a metodologia empregada. Também, quando cabíveis, serão apresentados fluxogramas detalhados de cada processo em figuras posteriores. Destaca-se que o fluxograma geral foi enumerado para facilitar a organização e entendimento da estrutura do trabalho.

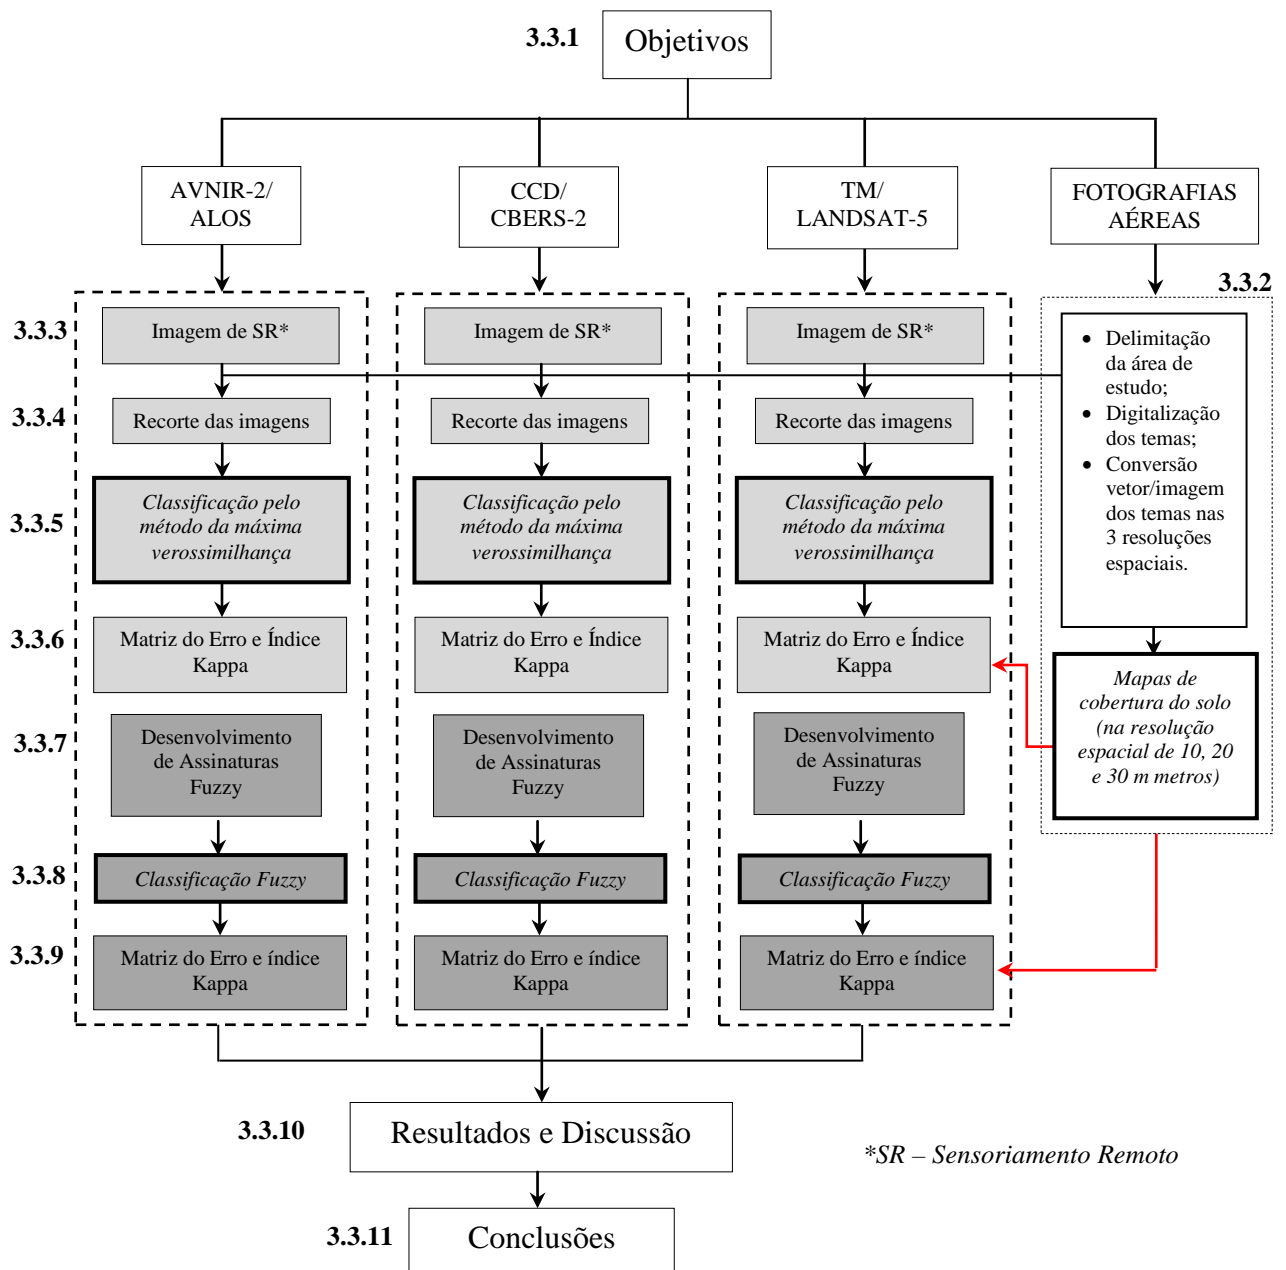


Figura 3.3 – Fluxograma geral do método.

3.3.1 Objetivos

Já descrito no item 1.1 do primeiro capítulo, este trabalho analisa o percentual de acerto e erro dos temas de mapas de cobertura do solo de uma região elaborados a partir de imagens tomadas por três sensores e mediante a utilização de dois diferentes métodos de classificação, Máxima Verossimilhança e Fuzzy. A comparação das classificações resultantes dos diferentes tipos de imagens com a verdade terrestre (fotografias aéreas) permitiu estimar a exatidão de cada um, sendo eles: AVNIR-2 do satélite ALOS, o CCD do satélite CBERS-2 e o *Thematic Mapper* do satélite LANDSAT-5.

3.3.2 Fotografias Aéreas

– *Delimitação da área de estudos*

As fotografias aéreas, na maioria das vezes, podem ser a verdade terrestre de uma área. O objetivo do uso das fotografias aéreas é a obtenção de mapa de cobertura do solo que seja referência e que sirva, nas etapas posteriores, para comparação com os resultados gerados pelo método da Máxima Verossimilhança e Fuzzy. Para seleção e delimitação da área de estudos foi utilizado um conjunto digital de 785 fotografias aéreas coloridas (em formato ‘.jpeg’) não georreferenciadas, as quais, após o devido georreferenciamento, ao serem introduzidas no *software* AutoCAD, formaram um foto-mosaico. Assim, foi identificado um trecho que apresentou os requisitos temáticos de cobertura do solo.

Neste mosaico foram identificados oito tipos de cobertura: água profunda; água rasa; área construída (estufas, asfalto, casas, telhas de amianto, telhas de zinco, telhas metálicas, piscinas); gramados (campos, taludes de estrada, campos de futebol, pasto); solo exposto; vegetação densa; cana e vegetação rala. Foram tomados estes temas em função da ocorrência dos mesmos no trecho escolhido e, a justificativa para a escolha do trecho consiste na presença da maioria dos tipos de cobertura da terra da bacia hidrográfica de São Carlos.

A determinação do trecho permitiu que fosse definido o perímetro da área, o qual coincide exatamente com as bordas das fotografias que compõem a área de estudo, possibilitando que todo o banco de dados fosse reduzido a este tamanho (as bandas e as composições coloridas falsa-cor).

– *Digitalização dos temas*

É necessária a compreensão da área de estudo pelo *software* utilizado (SIG) como um mapa de cobertura do solo. Se o trecho for inserido no *software* da forma que se encontra (em formato padrão de imagens, ‘.jpeg’) não é possível a diferenciação dos temas e, por esse motivo foi feita a digitalização dos temas, conforme o trabalho de Adami (2007), no *software* AutoCAD, obtendo arquivos vetoriais, um pra cada tema.

– *Conversão vetor/imagem dos temas nas três resoluções espaciais*

Os arquivos vetoriais resultantes do processo de digitalização sofreram conversão vetor/imagem resultando em oito imagens (uma para cada tema). Para finalizar, estes arquivos foram agrupados resultando em mapas de cobertura do solo baseados nas fotografias aéreas, cuja resolução é determinada também nesta etapa, quando é feita a conversão dos arquivos vetoriais.

Esta conversão utiliza uma imagem como parâmetro com o objetivo de fornecer para o mapa de cobertura do solo resultante da digitalização características como georreferenciamento e tamanho do pixel. Assim, para cada vetor é realizado este procedimento de conversão. Entretanto, sabe-se que o mapa de cobertura do solo resultado dos procedimentos descritos nesta sessão serão utilizados para comparar com o resultado das classificações digitais das imagens de sensoriamento remoto, as quais são apresentadas em três resoluções distintas. Por isso, cada tema foi convertido 3 vezes, cada uma delas utilizando uma imagem-base (com resolução espacial de 10, 20 e 30 metros). Posteriormente, como mostra a Figura 3.4, seqüencialmente foram somados os resultados da conversão vetor/imagem.

Resultam deste processo três mapas de verdade terrestres baseados no mosaico de fotografias aéreas coloridas: um com resolução espacial de 10 m, para ser comparado com o resultado da classificação digital produzida a partir de imagem do sensor AVNIR-2/ALOS; outro com resolução espacial de 20 m, a ser comparado com a classificação digital utilizando cena do sensor CCD/CBERS-2 e o terceiro, com resolução espacial de 30 m, para ser comparado com a classificação obtida sobre a imagem do sensor TM/LANDSAT-5.

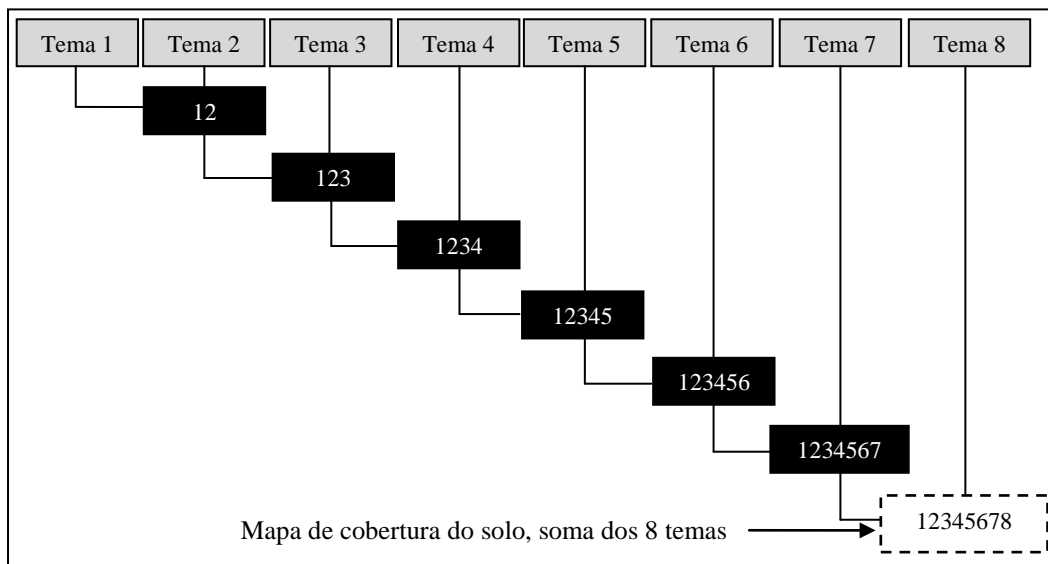


Figura 3.4 – Seqüência para a soma dos temas gerando o mapa de cobertura do solo baseado nas fotografias aéreas (verdade terrestre).

3.3.3 Imagens de Sensoriamento Remoto: AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5

Para o georreferenciamento de sensoriamento remoto utilizadas neste trabalho, criou-se primeiramente a composição colorida falsa-cor. Foram levantados em campo pontos que serviram de controle para o georreferenciamento, os quais foram, *a priori*, identificados na composição colorida.

As imagens dos sensores CCD/CBERS-2 e TM/LANDSAT-5 foram adquiridas no *site* do Instituto Nacional de Pesquisas Espaciais – INPE (para se compor a bacia hidrográfica de São Carlos foram necessárias duas órbitas/pontos quando utilizadas imagens do sensor CCD/CBERS-2). As imagens do sensor AVNIR-2/ALOS foram adquiridas através do Núcleo de Estudos, Planejamento Ambiental e Geomática da Universidade Federal de Itajubá junto à empresa Sulsoft LTDA (Sulsoft, 2008).

3.3.4 Recorte das imagens

Na Figura 3.5 pode-se acompanhar o procedimento necessário para se cortar uma banda das imagens dos sensores utilizados.

Verifica-se em (a) o limite utilizado para a redução das imagens dos sensores. O limite retangular definido pelas coordenadas $X_{\min} = 199.762$ m; $Y_{\min} = 7.545.329$ m; $X_{\max} = 201.112$ m e $Y_{\max} = 7.547.299$ m é o que envolve o limite do polígono; em (b) encontra-

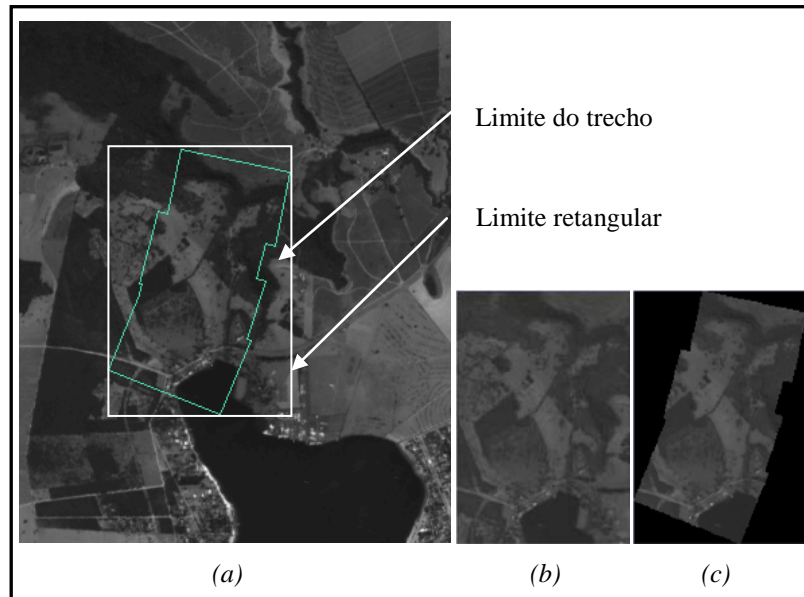


Figura 3.5 – Recorte das imagens utilizadas. Em (a) é focada uma área da cena do sensor AVNIR-2/ALOS; em (b) é mostrado o resultado do recorte mostrado na linha branca de (a) e em (c) encontra-se o resultado final do corte das bandas, representado pela linha verde da imagem (a).

se a redução da imagem ao tamanho do limite retangular. Para obter (c) foi multiplicada uma imagem booleana (zero para as áreas externas ao polígono e 1 para a área interna) por (b). Em (c) as áreas externas ao limite do trecho não são imagem, diferentemente de (a) e (b). A Tabela 3.1 mostra as características das imagens antes e após o recorte.

3.3.5 Classificações digitais pelo método da Máxima Verossimilhança das imagens dos sensores AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5

Após o georreferenciamento das bandas e recorte no tamanho da área de estudo, foi realizada composição colorida falsa-cor e aplicado o classificador da Máxima Verossimilhança. Para tanto, iniciou-se o procedimento adquirindo os dados de treinamento (Eastman, 1998).

A digitalização dos polígonos das áreas de treinamento é realizada coletando amostras das áreas que representam cada tema dando origem a dados vetoriais. Após esta amostragem das áreas de treinamento são desenvolvidas as assinaturas que são utilizadas para a elaboração do mapa de cobertura do solo empregando o algoritmo proposto.

Tabela 3.1 – Características das imagens brutas antes e após o corte.

Sensor/ Satélite	Imagens	Características antes do corte		Características depois do corte	
		Coordenadas	Tamanho da imagem	Coordenadas Geográficas (UTM)*	Tamanho da imagem
AVNIR-2/ ALOS	Composição Colorida Falsa-Cor	X _{mín} = 177472 m		X _{mín} = 199762 m	
	Banda 2	Y _{mín} = 7534959 m	Linhas: 8276	Y _{mín} = 7545329 m	Linhas: 197
	Banda 3	X _{máx} = 261712 m	Colunas: 8424 (resolução 10 m)	X _{máx} = 201112 m	Colunas: 135 (resolução 10 m)
	Banda 4	Y _{máx} = 7617719 m		Y _{máx} = 7547299 m	
CCD/ CBERS-2	Composição Colorida Falsa-Cor	X _{mín} = 93530 m		X _{mín} = 199762 m	
	Banda 2	Y _{mín} = 7458001 m	Linhas: 11602	Y _{mín} = 7545329 m	Linhas: 98
	Banda 3	X _{máx} = 265318 m	Colunas: 8275 (resolução 20 m)	X _{máx} = 201112 m	Colunas: 65 (resolução 20 m)
	Banda 4	Y _{máx} = 7692679 m		Y _{máx} = 7547299 m	
TM/ LANDSAT-5	Composição Colorida Falsa-Cor	X _{mín} = 104790 m		X _{mín} = 199762 m	Linhas: 66 Colunas: 46
	Banda 2	Y _{mín} = 7500017 m	Linhas: 6640	Y _{mín} = 7545329 m	
	Banda 3	X _{máx} = 341486 m	Colunas: 7897 (resolução 30 m)	X _{máx} = 201112 m	
	Banda 4	Y _{máx} = 7699037 m		Y _{máx} = 7547299 m	

* Meridiano Central 45° - UTM
Datum Córrego Alegre

3.3.6 Matriz do erro – Qualificação do método da Máxima Verossimilhança

Foram definidos parâmetros para avaliar os resultados das classificações digitais, pois estes são fundamentais para a validação do trabalho e do método utilizado. Assim, como já mostrado, optou-se pela utilização do Índice Kappa e da matriz do erro, amplamente utilizados como foi descrito no Capítulo 2.

Foram comparados os mapas de cobertura do solo baseados nas fotografias aéreas com os mapas gerados através da classificação digital por Máxima Verossimilhança como mostra o fluxograma da Figura 3.6.

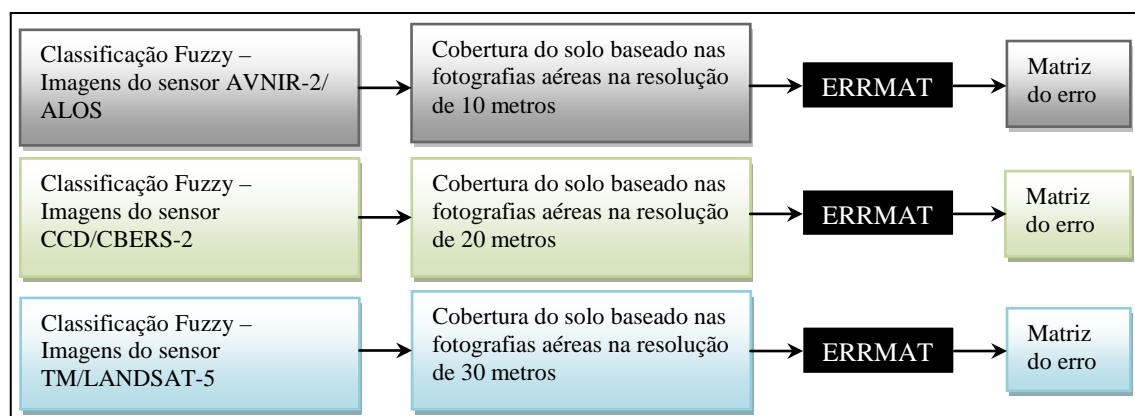


Figura 3.6 – Fluxograma da metodologia para a obtenção das matrizes do erro para a classificação Fuzzy.

Através da Matriz do Erro podem ser obtidos os erros de omissão e inclusão de pixels para cada tema e determinado do Índice Kappa, via função ERRMAT.

3.3.7 Desenvolvimento de assinaturas Fuzzy

No fluxograma da Figura 3.7 encontra-se um resumo do procedimento usado no desenvolvimento das assinaturas Fuzzy.

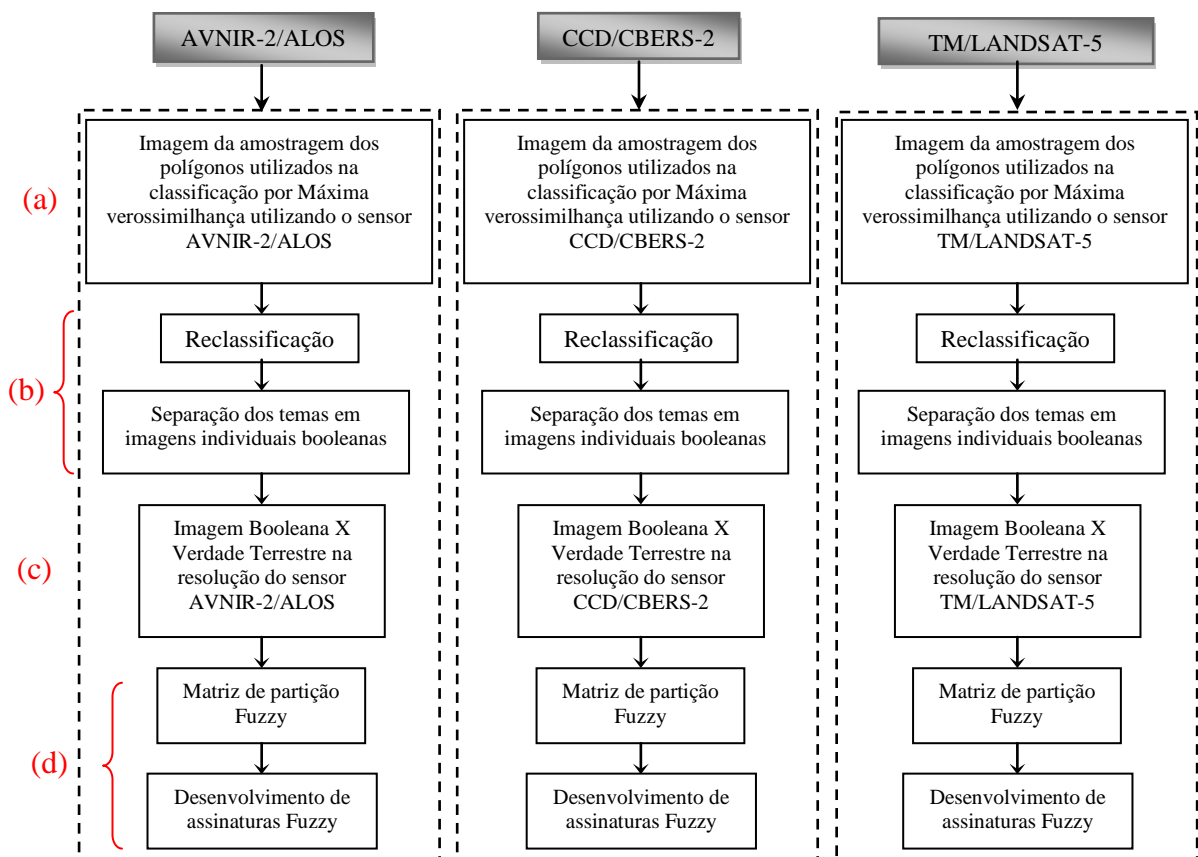


Figura 3.7 – Fluxograma do desenvolvimento das assinaturas Fuzzy.

As assinaturas Fuzzy são baseadas nos vetores de atributos das áreas de treinamento definido para a classificação da cobertura do solo por Máxima Verossimilhança no item 3.3.5, como mostra o a Figura 3.7(a).

O procedimento seguinte consistiu em reclassificar a imagem das áreas de treinamento amostradas, separando cada tema em um arquivo, como mostra a Figura 3.7 (b). Por exemplo, para o tema 1, água profunda, foi atribuído o valor “1” e aos demais temas o valor “0”, dando origem a uma imagem booleana tendo como verdade apenas o

tema 1 e desconsiderados os demais. O procedimento foi repetido para cada classe, restando em cada imagem um tema diferente.

A definição dos polígonos das áreas de treinamento foi feita com base na composição colorida e na verdade terrestre por mosaico das fotografias aéreas. Por esse motivo, durante a amostragem das áreas de treinamento, pode ser que os pixels de outros temas sejam inseridos em polígonos de amostragem de um tema específico. Estas interações podem ser apresentadas em forma de matriz, a chamada Matriz de Partição Fuzzy. Com as imagens booleanas criadas anteriormente e com os mapas de verdade terrestre foi possível se determinar os graus de pertinência de cada local de treinamento para cada classe. Foram multiplicadas as imagens booleanas e os mapas de cobertura do solo baseados nas fotografias aéreas, resultando, para cada tema, o que de fato existe nos polígonos amostrados, como sugere a Figura 3.7 (c).

Conforme Eastman (2006), uma matriz de partição Fuzzy indica os graus de pertinência de cada local de treinamento para cada classe e, dessa forma, Prado (2007) explica a montagem da Matriz de partição Fuzzy, conforme a Figura 3.7 (d):

“Na primeira coluna, denominada ID, deve constar identificadores numéricos inteiros para representar os dados de treinamento de cada classe de informação. Por exemplo, se existem seis classes, existirão seis identificadores numéricos (de 1 a 6) para representar cada amostra (ou grupos de dados de treinamento, se mais de uma amostra for usada por classe). Esses identificadores devem ser alocados em ordem crescente, um em cada linha da matriz. As colunas restantes da matriz de partição foram criadas conforme a quantidade de classes de informação existentes. Considerando, da mesma forma, que existem oito classes, devem ser criadas oito colunas, cada qual apresentando o nome de uma das classes de informação. Logo, as linhas da matriz de partição Fuzzy representam os locais de treinamento e as colunas, as classes. Assim, para N classes e M locais de treinamento, tem-se uma matriz $N \times M$.”

As matrizes de partição Fuzzy desenvolvidas a partir das suas assinaturas tiveram como resultados imagens através das quais se obteve a área de cada tema nos polígonos amostrados. Após a montagem da matriz e fazendo uso da função ASSING se obteve as assinaturas Fuzzy, gerando 8 novos arquivos, os denominados arquivos de valores de atributos (para cada conjunto de imagens: AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5) os quais relacionam os locais de treinamento com os valores (atributos) inseridos na matriz, os quais correspondem correspondentes à porcentagem de cada tema amostrado para a classificação por Máxima Verossimilhança.

Posteriormente, foram criadas imagens matriciais para expressar os graus de pertinência para cada classe. Para tanto, os arquivos de valores de atributo foram atribuídos à imagem rasterizada dos locais de treinamento.

3.3.8 Cobertura do solo utilizando a classificação Fuzzy para imagens dos sensores AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5

Desenvolvidos os arquivos de valores de atributos, o próximo passo constituiu em extrair as assinaturas Fuzzy, realizada através do módulo FIZSIG, juntamente com as bandas a serem processadas. Através do comando MAKESIG foram geradas as imagens classificadas. O procedimento foi realizado três vezes, gerando um conjunto de dados do sensor AVNIR-2/ALOS, outro do sensor CCD/CBERS-2 e um terceiro para o sensor TM/LANDSAT-5.

3.3.9 Matriz do erro – Qualificação da classificação Fuzzy

Da mesma forma descrita no item 3.3.5 deste capítulo, foram geradas as matrizes do erro entre os mapas de cobertura do solo usando a classificação Fuzzy e os mapas de cobertura do solo baseado nas fotografias aéreas. O fluxograma da Figura 3.8 (análogo ao da Figura 3.6) mostra a obtenção das novas matrizes e, no Capítulo 4 deste trabalho elas serão apresentadas, comparadas e discutidas.

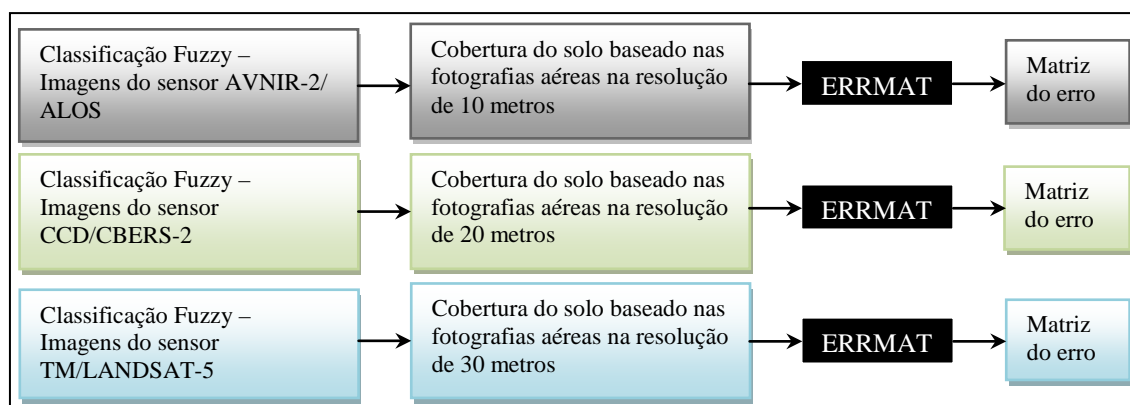


Figura 3.8 – Fluxograma da metodologia para a obtenção das matrizes do erro para a classificação Fuzzy.

3.3.10 Resultados e discussão

Os resultados são apresentados no Capítulo 4 e seguem a ordem:

- Mapas de cobertura do solo baseados nas fotografias aéreas (verdades terrestre);
- Mapas de cobertura do solo por meio das imagens de sensoriamento remoto utilizando o método da Máxima Verossimilhança;
- Mapas de cobertura do solo por meio das imagens de sensoriamento remoto utilizando o método da classificação Fuzzy;
- Análises comparativas pertinentes as áreas dos temas classificados por cada tipo de sensor.

3.3.11 Conclusões

Apresentadas no Capítulo 5 deste trabalho.

CAPÍTULO 4 - RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados todos os resultados deste trabalho, bem como as discussões cabíveis. O capítulo está dividido em cinco partes e um fluxograma (Figura 4.1) foi elaborado para facilitar a compreensão dos resultados a serem expostos, definidos nos seguintes subitens:

4.1 *Determinação da área de estudo*, mostrando o mosaico da área trabalhada com a indicação dos temas amostrados e justificativa dos mesmos;

4.2 *Mapa de cobertura do solo, verdade terrestre elaborada a partir das fotografias aéreas*, o qual mostra a construção dos resultados intermediários à formação dos mapas finais;

4.3 *Classificação dos tipos de cobertura do solo pelo método da Máxima Verossimilhança*, mostrando os vetores amostrados para a classificação em cada uma das composições coloridas falsa-cor (das imagens dos três sensores) e o resultado do método (três mapas de cobertura do solo utilizando imagens dos sensores AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5);

4.4 *Classificação dos tipos de cobertura do solo utilizando a classificação Fuzzy*, evidenciando a criação das matrizes de confusão e o desenvolvimento das assinaturas Fuzzy na utilização de cada um dos três sensores e

4.5 *Comparações* entre os resultados correspondentes as classificação obtidas utilizando as imagens do sensor AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5 e comparações relativas às áreas obtidas para cada tema.

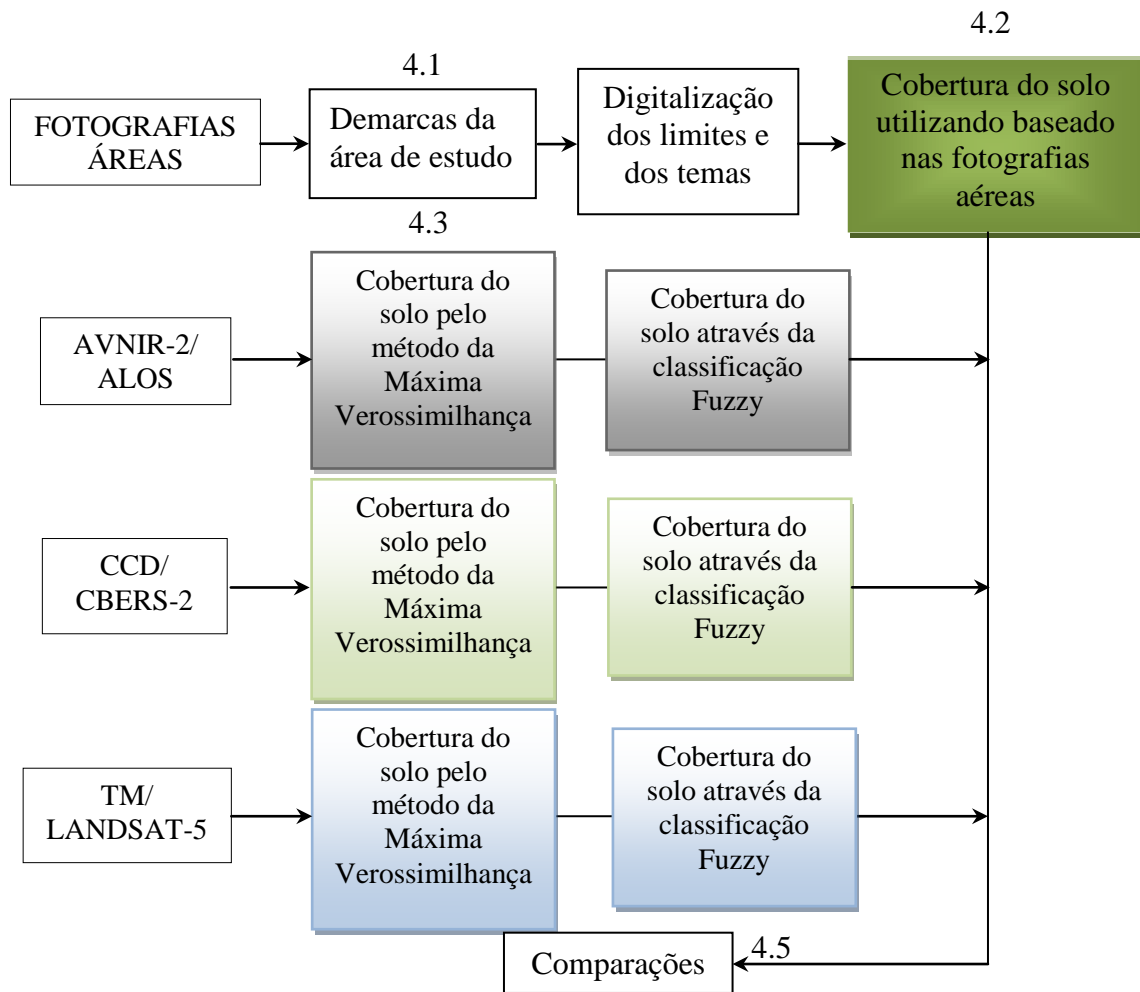


Figura 4.1 – Fluxograma dos resultados.

4.1 Demarcas da área de estudo

A área demarcada para a realização do trabalho encontra-se na Figura 4.2 (com aproximadamente 1,6 km² e perímetro 5,6 km), sendo possível a identificação de os oito tipos de cobertura do solo:

- *Tema 1* – Água profunda;
- *Tema 2* – Água rasa;
- *Tema 3* – Área construída (estufas, asfalto, casas, telhas de amianto, telhas de zinco, telhas metálicas, piscinas);
- *Tema 4* – Gramados (campos, taludes de estrada, campos de futebol, pasto);
- *Tema 5* – Solo exposto;
- *Tema 6* – Vegetação densa;
- *Tema 7* – Cana e
- *Tema 8* – Vegetação rala.




Figura 4.2 – Representação da área de estudo selecionada a partir de mosaico de fotografias aéreas.

Para o *tema 1*, água profunda, a identificação foi simples, uma vez que se apresenta características espectral diferente do restante do corpo d'água.

O *tema 2*, água rasa, também não ofereceu grandes dificuldades durante a sua identificação. O motivo considerado para se optar em amostrá-la se deve a possível confusão com o tema 1, água profunda, o que acabou não ocorrendo, uma vez que foram visualizadas as composições coloridas de cada um dos sensores utilizados e verificou-se respostas espectrais dos pixels correspondentes a este tema distintas.

Foi considerado também um tema onde fossem englobadas ações antrópicas, não se tratando de área urbana, mas área construída representante de construções de diversos tipos, envolvendo muros, casas, galpões com diversos tipos de coberturas, etc. Após análise detalhada do mosaico apresentado na Figura 4.2, foram considerados neste *tema 3* os seguintes elementos: casas, área construída (galpões, silos, ou quaisquer outras construções), telhados de diversos tipos de cobertura como telhas simples, telhas de amianto, zinco ou quaisquer outros tipos e piscinas que, apesar de conterem água, esta possui resposta espectral desigual das águas contempladas nos temas 1 e 2.

O *tema 4* relaciona vegetação rasteira como as áreas para pastagem animal, margens de estradas, campos de futebol e áreas gramadas. Na Figura 4.2 podem ser percebidas diferentes tonalidades para este tema, devido ao tipo de vegetação mudar em alguns locais, ao tamanho das plantas, diferentes espécies vegetais presentes e também ao espaçamento entre as plantas.

O *tema 5* corresponde a parcela de solo exposto. Este pode ser verificado em áreas desprovidas totalmente de qualquer tipo de vegetação como estradas em solo “batido” e áreas onde o solo está preparado para plantação. Também foram digitalizadas como solo exposto áreas que não se tratam de estradas sem pavimentação, aquelas preparadas para plantio como espaços abertos e campos sem vegetação.

O *tema 6* representa a vegetação densa, facilmente visualizada na Figura 4.2. Porém, um tema expressivo na bacia hidrográfica estudada é o plantio de laranjas. Em estudos pilotos realizados pelo mesmo autor desse trabalho na bacia hidrográfica de São Carlos constatou-se que, para as imagens utilizadas, a vegetação densa confunde-se com laranjais, optando por não considerar amostragem desses dois temas separadamente. Esta consideração está sendo feita não apenas porque aparecem plantações de laranjas na área piloto escolhida para este trabalho, mas também pelas freqüentes aparições deste tema em outras partes da bacia.

O *tema 7* considerado nos mapeamentos de cobertura do solo é referente à cultura de cana, cuja cultivo na bacia hidrográfica estudada é observado em inúmeras áreas e, por apresentar forma, textura e cor facilmente distinguível da vegetação densa amostrada no *tema 6*, apresentando coloração verde-clara, oferece resposta espectral bem particular facilitando a amostragem e a classificação digital.

Por fim, o *tema 8* faz referência a amostragem de vegetação rala, cuja resposta espectral apresenta disparidade ao ser comparada à vegetação densa referente ao *tema 6*, decorrente do espaçamento entre plantas, o qual proporciona o destaque do solo que, por si só, apresentam características físico-químicas retratadas pelos sensores espaciais.

4.2 Mapa de cobertura do solo baseado nas fotografias aéreas

A elaboração dos mapas de cobertura do solo baseados nas fotografias aéreas para servirem como verdade terrestre, como visto no item 3.3.2, se iniciou com a digitalização em plataforma CAD das oito classes de cobertura do solo apresentadas na Figura 4.2. Observando a Figura 4.3 percebe-se a forma minuciosa com que este processo de digitalização foi feito (vide também a Figura 4.2). Verifica-se a fidelidade da digitalização com relação às fotografias.

A Figura 4.5 mostra o resultado da cobertura do solo referente às fotografias aéreas na resolução do sensor CCD/CBERS-2, o qual serviu para comparar com a classificação resultante dos processos de classificação digital, com resolução espacial de 20 metros, ou seja, cada pixel possui uma área quadrada no valor de 400 m².

Pode-se afirmar que um pixel na resolução do sensor AVNIR-2/ALOS equivale a ¼ do pixel na resolução do sensor CCD/CBERS-2 ou então, que o pixel de uma imagem de resolução de 20 metros equivale a quatro pixels de uma imagem em resolução de 10 metros.

Na Figura 4.6 é mostrada a cobertura do solo baseada nas fotografias aéreas na resolução do sensor TM/LANDSAT-5, ou seja, cada pixel apresenta 30 metros de lado, totalizando uma área de 900 m² cada um. Assim, um pixel da imagem do sensor TM/LANDSAT-5 é 2,25 vezes maior que um pixel do sensor CCD/CBERS-2 e/ou também 9 vezes maior que um pixel de imagens do sensor AVNIR-2/ALOS.

No mapa de cobertura do solo apresentado na Figura 4.4 (na resolução espacial de 10 m) se encontra o número de pixels pertencentes a cada classe temática.



Figura 4.3 – Vetores dos temas digitalizados – base para a elaboração dos mapas de cobertura do solo baseados nas fotografias aéreas para as 3 resoluções espaciais.

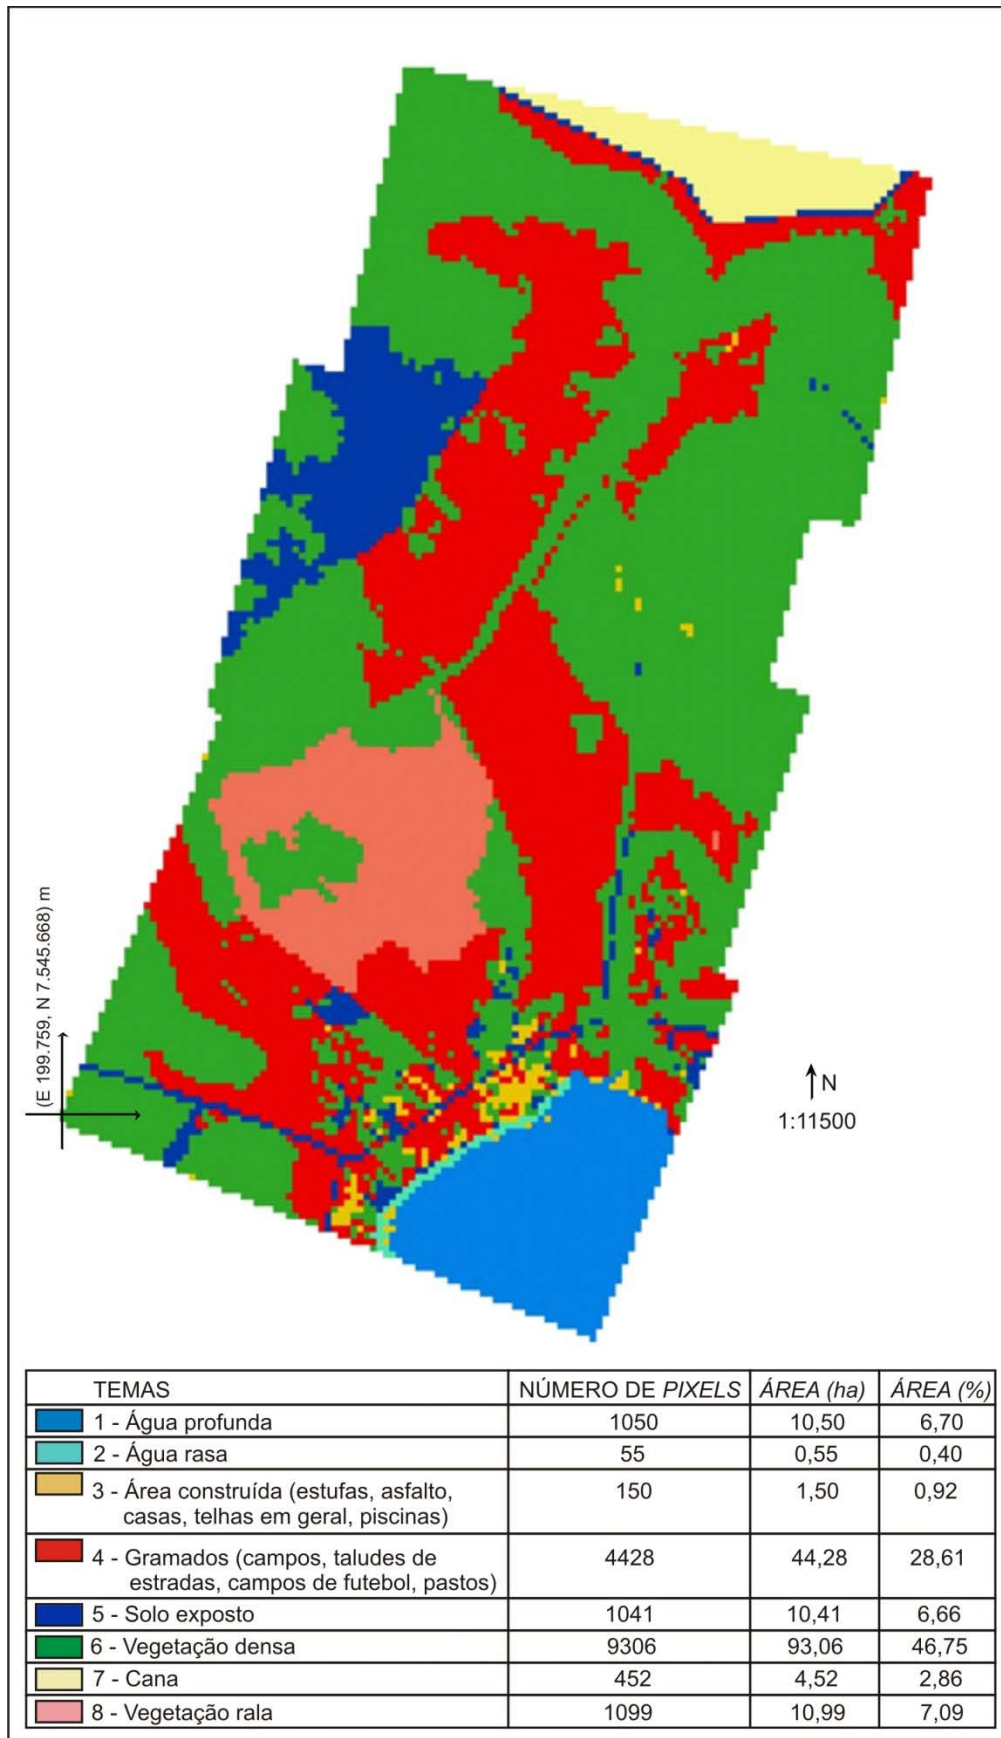


Figura 4.4 – Mapa de cobertura do solo baseado nas fotografias aéreas com resolução espacial do sensor AVNIR-2/ALOS.

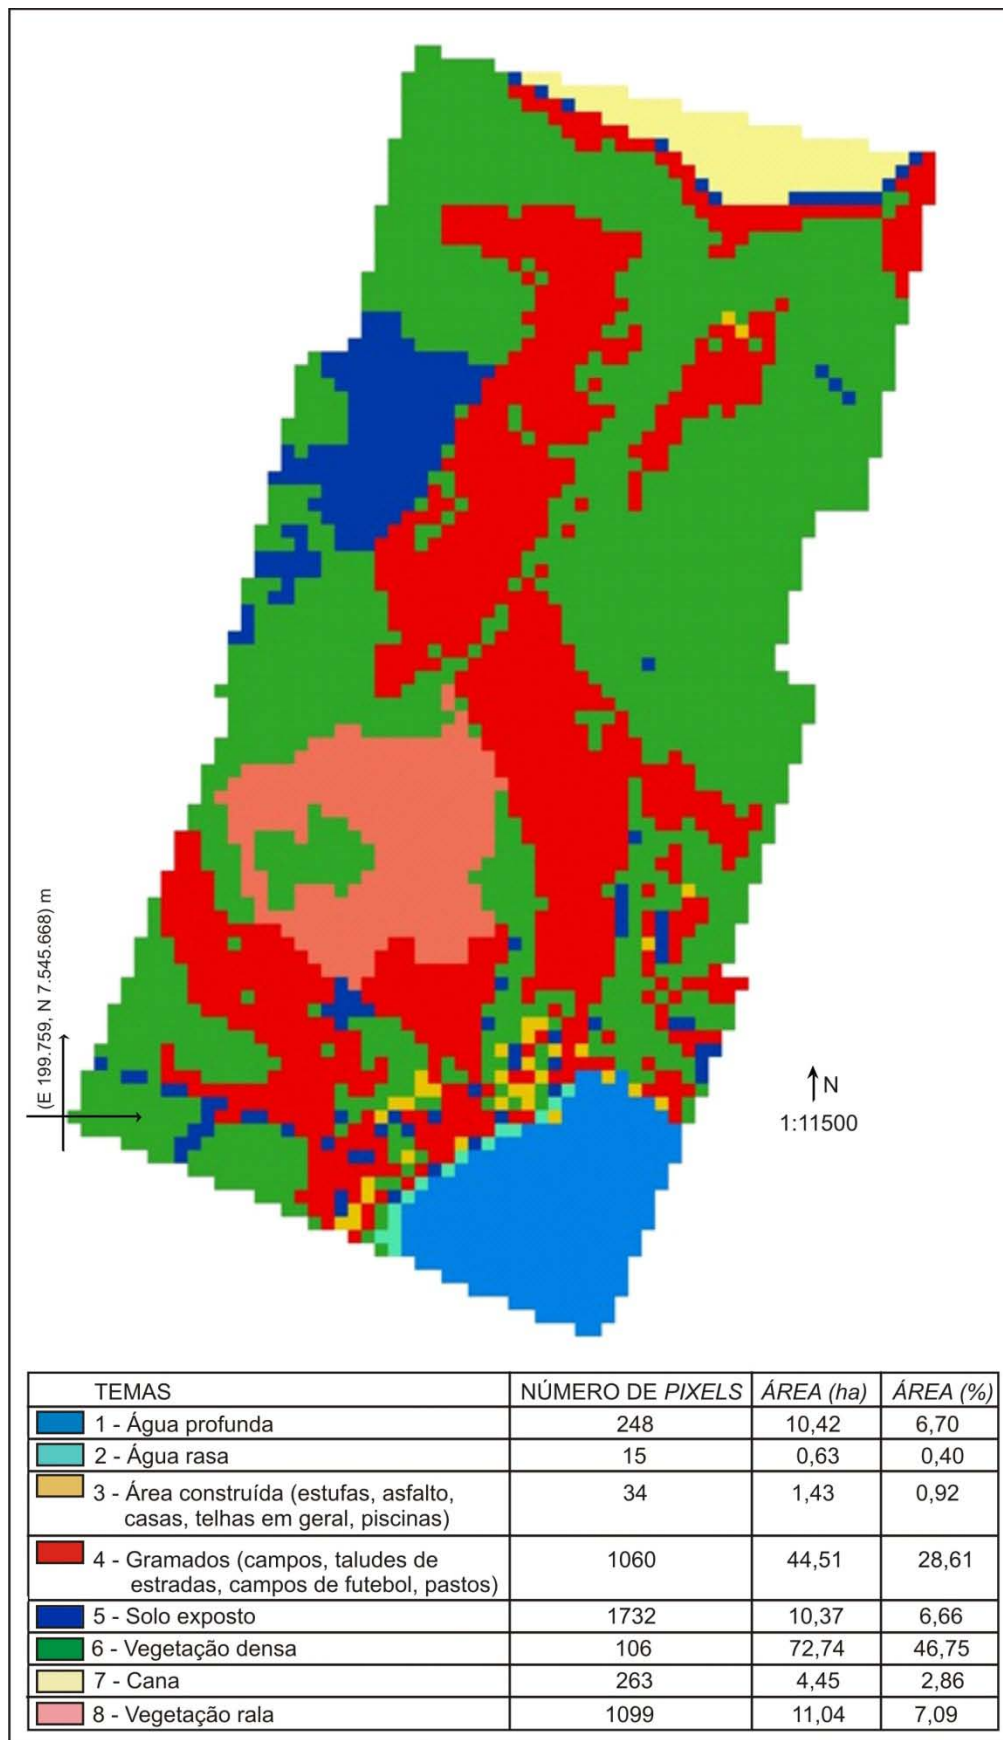


Figura 4.5 – Mapa de cobertura do solo baseado nas fotografias aéreas com resolução espacial do sensor CCD/CBERS-2.




Figura 4.6 – Mapa de cobertura do solo baseado nas fotografias aéreas com resolução espacial do sensor TM/LANDSAT-5.

Como se pode perceber, a área relativa aos temas nas três resoluções não exatamente iguais, ficando pequenas diferenças justificadas por conta da resolução. O aumento das dimensões dos pixels (resolução espacial) é a diferença fundamental.

4.3 Classificação pelo método da Máxima Verossimilhança

4.3.1 Cobertura do solo utilizando imagens do sensor AVNIR-2/ALOS

A classificação digital supervisionada pelo método da Máxima Verossimilhança inicia-se pela amostragem de polígonos sobre a composição colorida (RGB 342) proveniente das bandas do sensor AVNIR-2/ALOS (Figura 4.7); depois de aplicado o classificador, o resultado é o mapa de cobertura do solo apresentado na Figura 4.8.




Figura 4.7 – Áreas de treinamento amostradas para a classificação Máxima Verossimilhança utilizando imagem do sensor AVNIR-2/ALOS.

A matriz do erro resultante da comparação do mapa de cobertura do solo baseado nas fotografias aéreas coloridas – Figura 4.4 com a classificação resultante da aplicação do método da Máxima Verossimilhança para imagens do sensor AVNIR-2/ALOS (usando a ferramenta do software de geoprocessamento denominada ERRMAT) é mostrada na Tabela 4.1.

Exemplificando a leitura da Tabela 4.1, em se tratando do tema 1, água profunda, constata-se que dos 15581 pixels que compõem a imagem, 1025 (102.500 m²) foram classificados corretamente nesse tema, correspondendo a um erro de omissão de 2,19 % – pois dos 1048 pixels que correspondem a classe 1 no mapa classificado por Máxima Verossimilhança excluindo os 1025 classificados corretamente, 15 foram alocados para o

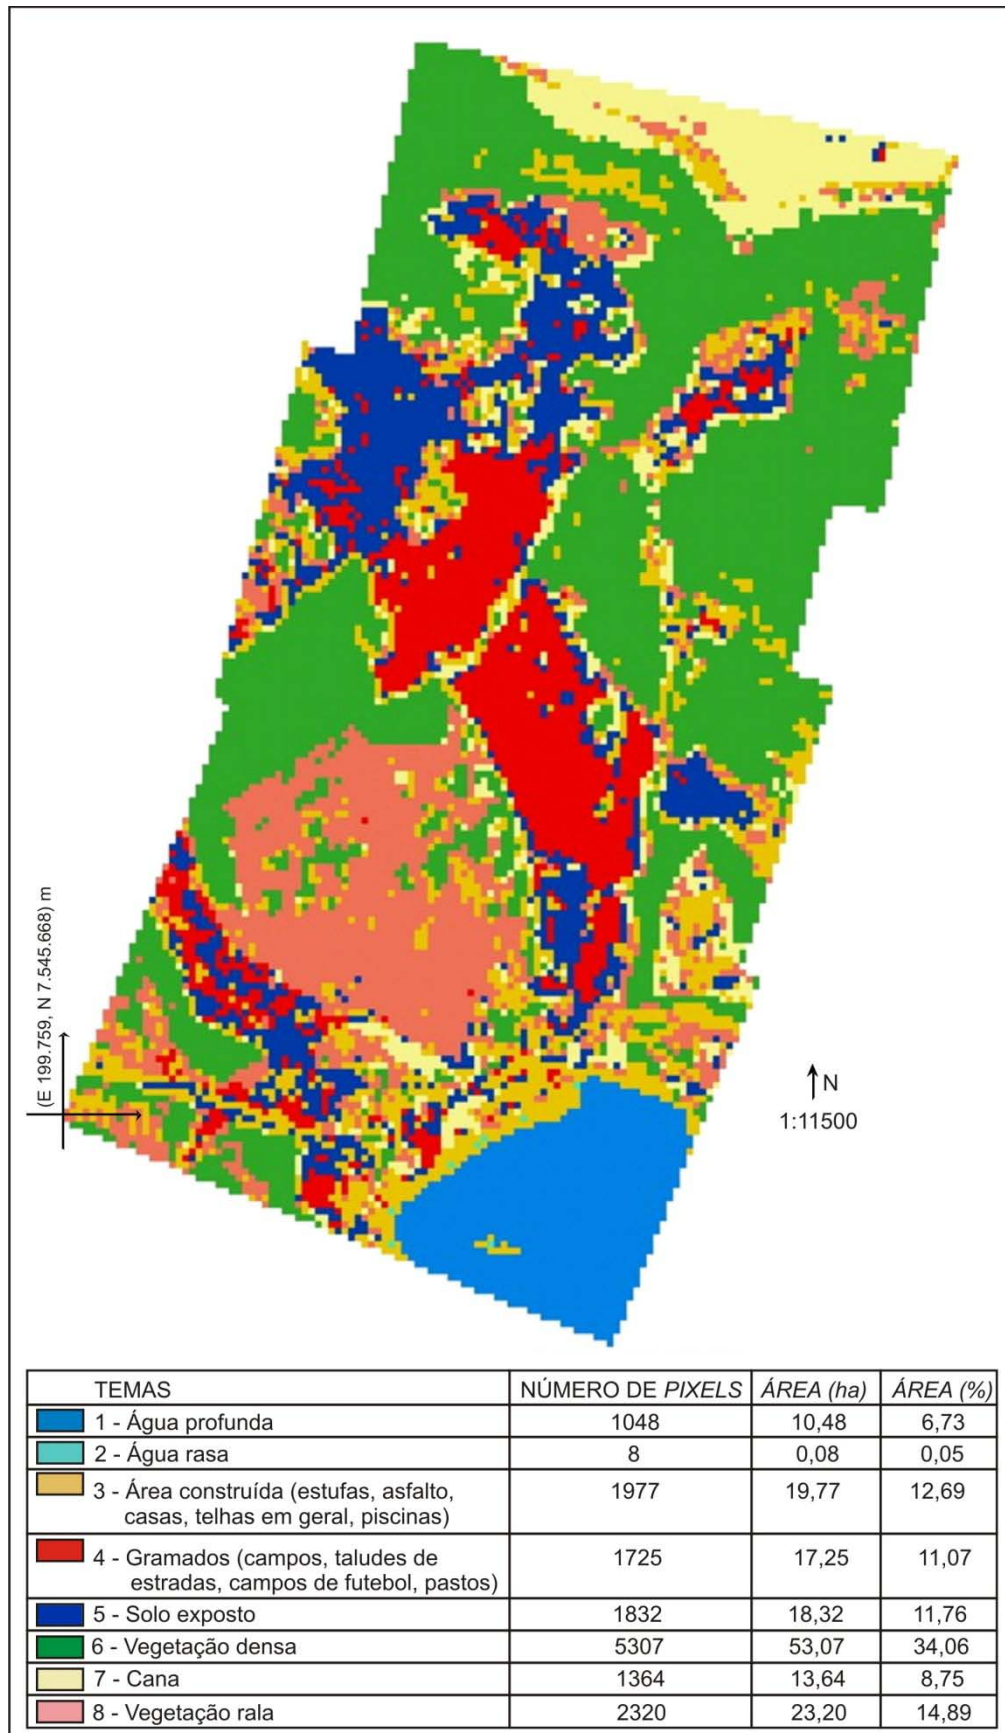


Figura 4.8 – Classificação da imagem AVNIR-2/ALOS pelo método da Máxima Verossimilhança

Tabela 4.1 – Matriz do erro resultante da tabulação cruzada entre o mapa de cobertura do solo da classificação supervisionada resultante da aplicação do método da Verossimilhança da imagem AVNIR-2/ALOS.

Tema \ Tema	1	2	3	4	5	6	7	8	Soma	ERRO DE INCLUSÃO
1	1025	15	8	0	0	0	0	0	1048	0,0219
2	1	3	1	1	2	0	0	0	8	0,6250
3	24	37	87	551	204	953	25	96	1977	0,9560
4	0	0	16	1509	92	103	2	3	1725	0,1252
5	0	0	10	1031	491	292	5	3	1832	0,7320
6	0	0	8	243	52	4816	0	188	5307	0,0925
7	0	0	8	447	50	436	395	28	1364	0,7104
8	0	0	12	646	150	706	25	781	2320	0,6634
Soma	1050	55	150	4428	1041	7306	452	1099	15581	
ERRO DE OMISSÃO	0,024	0,942	0,420	0,653	0,528	0,341	0,126	0,289		

tema 2 e 8 para o tema 3. Em contrapartida, foi encontrado um erro de omissão de 2,4% - pois dos 1050 pixels referentes ao tema 1 no mapa de verdade terrestre (que deviam ter sido classificados como tema 1), excluindo 1025 que foram corretamente classificados, 24 foram erroneamente classificados como tema 3 e 1 como tema 2.

Esse tipo de análise foi feita para os demais temas e o seu intuito é avaliar a classificação de cada tema em relação à verdade terrestre. Assim, é importante constatar que, vistos os erros de omissão e inclusão, o tema 1 foi o que apresentou menores confusões, sendo classificada, a grande maioria dos seus pixels, no tema a que realmente correspondem.

Comparando-se às Figuras 4.8 e 4.4 (classificação por Máxima Verossimilhança de cena do sensor AVNIR-2/ALOS e verdade terrestre com resolução espacial de 10 m) nota-se considerável semelhança na disposição dos temas ao longo do trecho, porém é nítida a confusão nas áreas de transição entre os mesmos, fato que contribui para a diminuição da qualidade da classificação. Outros motivos devem ser considerados na tentativa de se justificar a qualidade da classificação: a utilização de imagens de média resolução espacial, incorporando ambigüidades (Boschi e Galo, 2007) e a mistura de temas em alguns pontos onde os alvos são de tamanho relativamente reduzido. Gao e Lui (2008) embasam esta afirmação quando dizem que as propriedades dos sensores, como sua resolução espacial, interferem diretamente em sua habilidade para discriminar classes, assim como Islam (2004) ao afirmar que a variabilidade dos dados diminui com a diminuição da resolução espacial. Inversamente, a variabilidade aumenta com o aumento da resolução espacial.

A partir da Tabela 4.1, conforme bibliografias consideradas neste trabalho, obtém-se o do Índice Kappa. Para a cobertura do solo utilizando-se imagens do sensor AVNIR-

2/ALOS (Figura 4.8), por Máxima Verossimilhança, encontrou-se um Índice Kappa de 0,4688, qualificando a classificação como boa, de acordo com Landis e Koch (1977).

4.3.2 Cobertura do solo utilizando imagens do sensor CCD/CBERS-2

O resultado da classificação digital utilizando imagens do sensor CCD/CBERS-2 foi obtido através de composição colorida falsa-cor 342 (RGB), com amostragem de polígonos conforme a Figura 4.9. Na Figura 4.10 encontra-se o mapa de cobertura do solo obtido após o emprego do método da Máxima Verossimilhança. Como no item 4.3.1, é realizada a comparação entre a verdade terrestre (agora com resolução espacial de 20 m) e a classificação da cena do sensor CCD/CBERS-2 resultando em uma nova matriz do erro (Tabela 4.2).




Figura 4.9 – Áreas de treinamento para a classificação Máxima Verossimilhança utilizando imagens do sensor CCD/CBERS-2.

Tabela 4.2 – Matriz do erro resultante da tabulação cruzada entre o mapa de cobertura do solo da classificação resultante da aplicação do método da Verossimilhança da imagem CCD/CBERS-2.

Tema \ Tema	1	2	3	4	5	6	7	8	Soma	ERRO DE INCLUSÃO
1	185	0	0	0	0	0	0	0	185	0
2	24	0	0	0	0	0	0	0	24	1
3	0	0	9	27	20	11	0	0	67	0,8657
4	17	13	7	749	75	336	3	49	1249	0,4003
5	1	0	9	153	113	109	0	8	393	0,7125
6	18	0	4	76	17	1048	0	52	1251	0,1335
7	0	0	0	7	12	1	103	0	123	0,1626
8	3	2	5	48	10	191	0	154	413	0,6271
Soma	248	15	34	1060	247	1732	106	263	3705	
ERRO DE OMISSÃO	0,2540	1	0,7353	0,2934	0,5425	0,3741	0,0283	0,4144		

Como na análise da matriz do erro mostrada na Tabela 4.1, na Tabela 4.2, referente ao tema 1, água profunda, constatou-se que dos 3705 pixels que compõem a imagem, 185 foram classificados no tema 1, porém na verdade terrestre este tema apresenta 248 pixels. Entretanto, na classificação por Máxima Verossimilhança não houve erro de inclusão, uma vez que dos seus 185 pixels, todos fazem parte do tema 1 apresentado na verdade terrestre. Em relação aos erros de omissão, na classificação deveria haver 245 no tema 1, mas foram apenas classificados 185. Esta diferença corresponde aos 24 pixels omitidos pelo tema 2, 17 pelo tema 4, 1 pelo tema 5, 18 pelo tema 6 e 3 pelo tema 8, reportando um erro de omissão de 25,4%.

Percebe-se, através da compreensão da matriz do erro, que alguns temas obtiveram uma classificação ruim, como o 2 (água rasa) e o 3 (área construída). Os erros de inclusão e omissão se aproximaram de 100%, concluindo que quase a totalidade dos pixels pertencentes a determinados temas se classificaram em outros (tema 3) ou, para determinados temas, os pixels classificados não correspondem ao tema no qual foi inserido (tema 2). Alguns temas não apresentaram grandes problemas na classificação, como o tema 6 (vegetação densa) e o tema 7 (cana). Como discutido no item 4.3.1, a resolução mediana da imagem do sensor CCD/CBERS-2 não permite que a discriminação dos alvos, após a classificação supervisionada, seja tão minuciosa. Assim, percebe-se que alguns temas, por serem mais homogêneos, têm sua classificação com maior qualidade. Outros, porém, como no caso do que representa as áreas edificadas (3), por serem heterogêneos e apresentarem tamanhos reduzidos, apresentam maiores dificuldades na classificação.

Em relação à acurácia da classificação trazida através da matriz do erro, encontrou-se um valor de 0,5139, que, conforme Landis e Koch (1977), é considerada boa. Dessa forma, assim como se constata na classificação de imagem do sensor AVNIR-2/ALOS, percebe-se também aqui a influência da resolução espacial na qualidade da classificação (Gao e Liu, 2008).

Comparando-se a Figura 4.10 e 4.5 (cobertura do solo e verdade terrestre, respectivamente) se observa também as dificuldades na classificação nas áreas de transição dos temas. Porém, esta classificação apresenta, mesmo que ligeiramente, maior qualidade quando é comparada com a classificação apresentada na Figura 4.9 (cobertura do solo com imagem do sensor AVNIR-2/ALOS).




Figura 4.10 – Classificação da imagem CCD/CBERS-2 pelo método da Máxima Verossimilhança

4.3.3 Cobertura do solo utilizando imagens do sensor TM/LANDSAT-5

A classificação da imagem do sensor TM/LANDSAT-5 é limitada quando comparada aos outros sensores considerados no tocante à resolução espacial. Constam na Figura 4.11, as áreas de treinamento que representam os temas do trecho coletadas em composição colorida falsa-cor 342 (RGB) para a classificação supervisionada através do método da Máxima Verossimilhança.

Na Figura 4.12 é apresentado o resultado da classificação da cobertura do solo através de imagem do sensor TM/LANDSAT-5, utilizando a classificação Máxima Verossimilhança. Comparando-se a verdade terrestre (Figura 4.6, com resolução espacial de 30 m) a este mapa de cobertura do solo, obteve-se a matriz do erro mostrada na Tabela 4.3, possibilitando que se tenha uma pré-avaliação da classificação realizada.

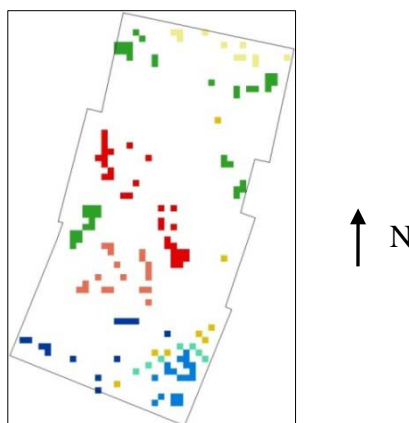


Figura 4.11 – Áreas de treinamento para a classificação Máxima Verossimilhança utilizando imagens do sensor TM/LANDSAT-5.

Através dessa comparação percebe-se visualmente uma qualidade inferior da classificação quando comparada com as classificações mostradas anteriormente, uma vez que este trabalho analisa apenas as diferenças entre resoluções espaciais. Percebe-se que o tema cana (7) aparece em toda disposição do trecho analisado sendo que, segundo os mapas de verdade terrestres, este somente existe na parte superior da área. Assim, pode-se perceber que um tema com características particulares (principalmente dos temas referentes à vegetação) se confundiu com os demais, não ocorrido ao serem utilizadas imagens dos sensores AVNIR-2/ALOS ou CCD/CBERS-2. Considerando a matriz do erro (Tabela 4.3), percebe-se que o tema 2 (água rasa) apresenta-se com altos valores de erros de inclusão e omissão, assim como o tema 5 (solo exposto). Em se tratando do tema 2, nenhum pixel correspondente a esse tema foi classificado como tal.

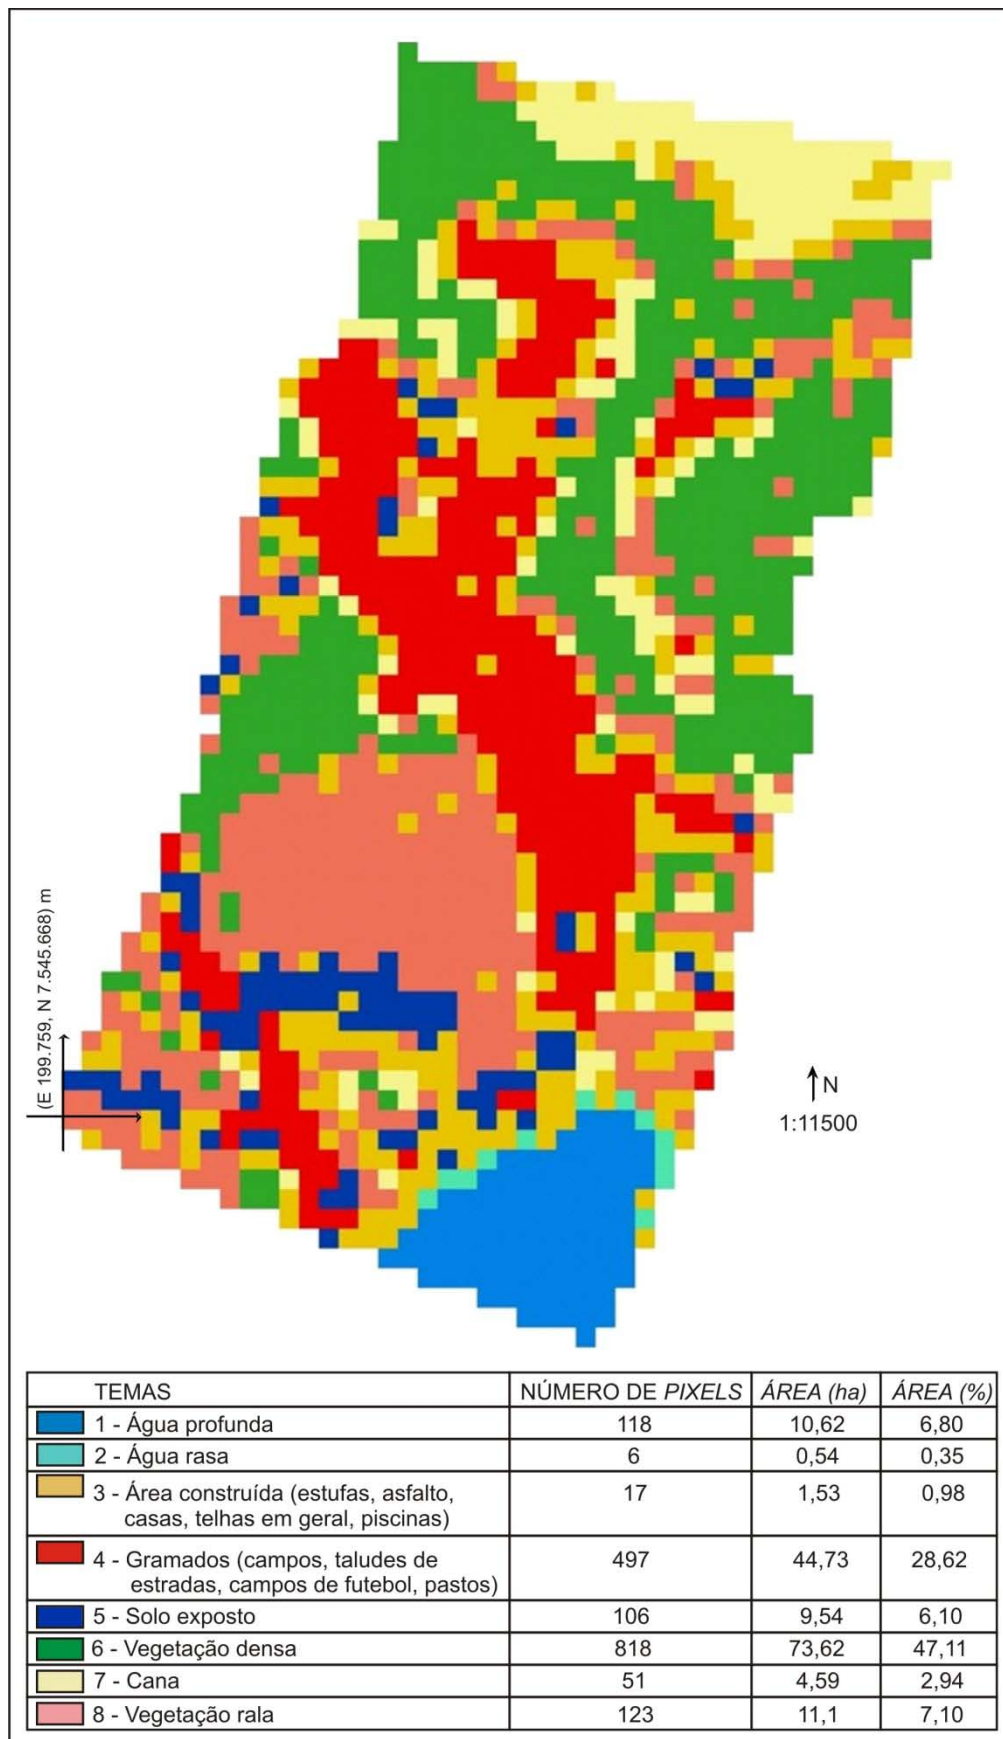


Figura 4.12 – Classificação da imagem TM/LANDSAT-5 pelo método da Máxima Verossimilhança.

Tabela 4.3 – Matriz do erro resultante da tabulação cruzada entre o mapa de cobertura do solo da classificação resultante da aplicação do método da Verossimilhança da imagem TM/LANDSAT-5.

Tema \ Tema	1	2	3	4	5	6	7	8	Soma	ERRO DE INCLUSÃO
1	94	1	0	0	0	0	0	0	95	0,0105
2	12	0	0	0	0	0	0	0	12	1
3	10	5	2	102	22	125	9	9	284	0,9930
4	0	0	4	220	42	39	0	0	305	0,2787
5	0	0	4	51	11	23	0	3	92	0,8804
6	0	0	2	22	5	381	0	11	421	0,0950
7	1	0	3	33	7	83	42	0	169	0,7515
8	1	0	2	69	19	167	0	100	358	0,7207
Soma	118	6	17	497	106	818	51	123	1736	
ERRO DE OMISSÃO	0,2034	1	0,8824	0,5573	0,8962	0,5342	0,1765	0,1870		

Pode-se justificar o resultado insatisfatório desta classificação através das bandas utilizadas, as quais não separaram os temas de interesse deste trabalho de forma favorável ao tipo de classificação e também à resolução do pixel de 30 metros. Observando até mesmo as composições coloridas feitas para a amostragem dos temas, verifica-se a discrepância esperada do sensor TM/LANDSAT-5 para com os demais no que diz respeito à nitidez e resolução, para uma área de área reduzida como esta (em relação à resolução espacial).

O Índice Kappa para esta classificação, inferior aos demais, é de 0,3144, o qual qualifica a classificação obtida como razoável, segundo Landis e Koch (1977).

4.4 Classificação Fuzzy

4.4.1 Cobertura do solo utilizando imagem do sensor AVNIR-2/ALOS

A matriz de partição Fuzzy representada pelo conteúdo de cada polígono amostrado na classificação por Máxima Verossimilhança apresentada no item 3.3.7 é mostrada na Tabela 4.4. Separando da Tabela 4.4 os valores em porcentagem obtêm-se a Tabela 4.5, a qual recebe o nome de matriz de partição Fuzzy. Após a elaboração da matriz de partição Fuzzy e a partir de imagem do sensor AVNIR-2/ALOS, através dos comandos FUZLIKE e MAKESIG, obtêm-se o mapa de cobertura do solo apresentado na Figura 4.13. Para análise desta classificação foi gerada a matriz do erro (Tabela 4.6) e seu respectivo Índice Kappa.

Tabela 4.4 – Área dos temas presentes nos polígonos de amostragem das áreas de treinamento para a elaboração da matriz de partição Fuzzy.

Tema	1		2		3		4		5		6		7		8	
	área [m ²]	%	área [m ²]	%	área [m ²]	%	área [m ²]	%	área [m ²]	%	área [m ²]	%	área [m ²]	%	área [m ²]	%
1	9200	0,98	100	0,2	-	-	-	-	-	-	-	-	-	-	-	-
2	200	0,02	200	0,4	-	-	-	-	-	-	-	-	-	-	-	-
3	-	-	100	0,2	200	0,07	-	-	-	-	-	-	-	-	-	-
4	-	-	100	0,2	600	0,2	11300	0,97	700	0,08	-	-	400	0,05	1500	0,29
5	-	-	-	-	700	0,23	-	-	8000	0,90	-	-	100	0,01	-	-
6	-	-	-	-	1500	0,5	300	0,03	200	0,02	38900	1	-	0,94	-	-
7	-	-	-	-	-	-	-	-	-	-	-	8200	-	-	-	-
8	-	-	-	-	-	-	-	-	-	-	-	-	-	-	3700	0,71

Tabela 4.5 – Matriz de partição Fuzzy

IDR_ID	1	2	3	4	5	6	7	8
1	0,9787	0,0213	0	0	0	0	0	0
2	0,2	0,4	0,2	0,2	0	0	0	0
3	0	0	0,0667	0,2	0,2333	0,5	0	0
4	0	0	0	0,9741	0	0,0259	0	0
5	0	0	0	0,0787	0,8989	0,0225	0	0
6	0	0	0	0	0	1	0	0
7	0	0	0	0,0460	0,0115	0	0,9425	0
8	0	0	0	0,2885	0	0	0	0,7115

Tabela 4.6 – Matriz do erro comparando o mapa de cobertura do solo baseado nas fotografias aéreas na resolução espacial do sensor AVNIR-2/ALOS com o mapa de cobertura do solo das imagens do sensor AVNIR-2/ALOS obtido através da classificação Fuzzy.

Tema	1	2	3	4	5	6	7	8	Soma	ERRO DE INCLUSÃO
1	1027	8	5	0	0	0	0	0	1040	0.0125
2	12	38	6	2	3	2	0	0	63	0.3968
3	11	8	45	67	44	207	0	1	383	0.8825
4	0	1	25	2187	193	400	6	26	2838	0.2294
5	0	0	30	632	486	172	0	1	1321	0.6321
6	0	0	27	881	220	6078	122	606	7934	0.2339
7	0	0	3	205	26	208	323	9	774	0.5827
8	0	0	9	454	69	239	1	456	1228	0.6287
Soma	1050	55	150	4428	1041	7306	452	1099	15581	
ERRO DE OMISSÃO	0.0219	0.3091	0.7000	0.5061	0.5331	0.1681	0.2854	0.5851		

Em análise das matrizes do erro para a classificação por Máxima Verossimilhança e Fuzzy, obtidas a partir de imagem do sensor AVNIR-2/ALOS, pode-se, no geral, constatar que as áreas dos temas classificados por Fuzzy se aproximam mais das áreas dos temas apresentados na verdade terrestre do que os temas classificados por Máxima Verossimilhança.

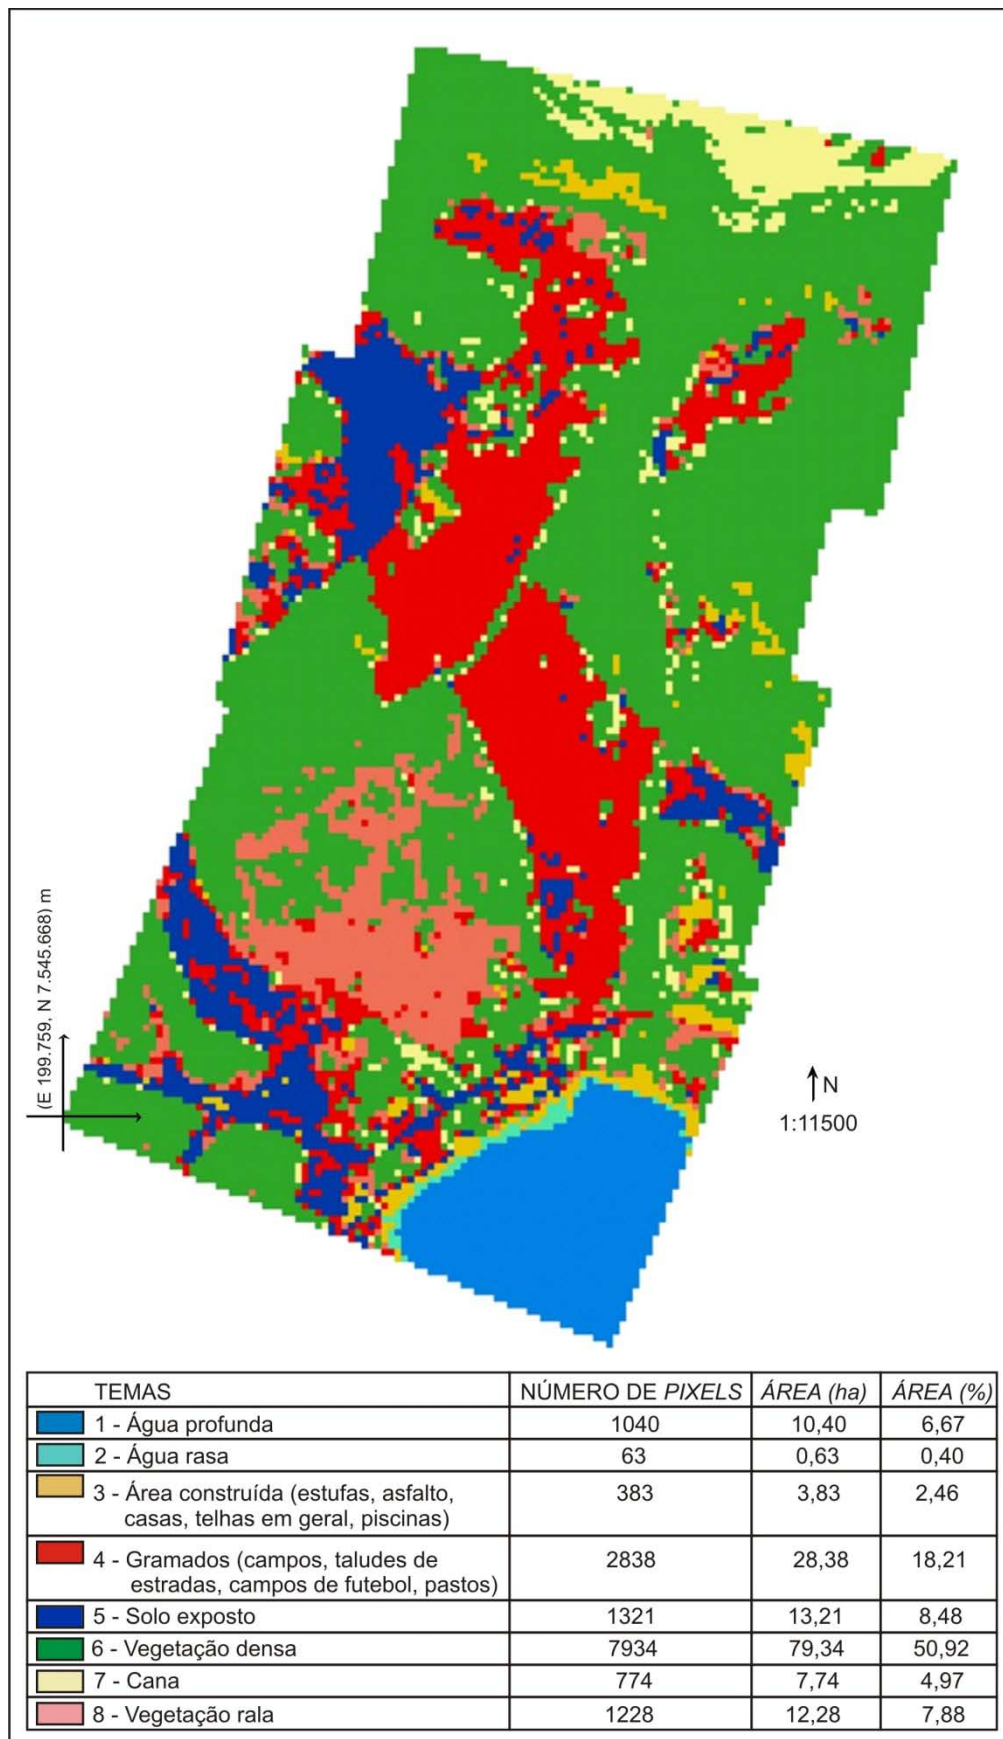


Figura 4.13 – Classificação Fuzzy da imagem do AVNIR-2/ALOS.

A partir da matriz do erro apresentada na Tabela 4.1 e na Tabela 4.6 foram obtidos os gráficos apresentados na Figura 4.14 e na Figura 4.15, os quais mostram comparações entre os erros de omissão e inclusão ao serem utilizados os dois classificadores.

De acordo com a Figura 4.14, percebe-se que em relação aos erros de omissão (aos pixels que deviam ser enquadrados em determinado tema e não foram), a classificação Fuzzy diminuiu esse tipo de erro para os temas 1 (água profunda), 2 (água rasa), 4 (gramados, campos, taludes de estrada, campos de futebol, pasto) e 6 (vegetação densa), tendo os seus valores aumentados ou permanecendo inalterados.

Em relação à Figura 4.15, a qual relaciona a comparação dos valores dos erros de inclusão antes, só com o classificador Máxima Verossimilhança, e depois, com o classificador Fuzzy, constata-se que com a utilização deste classificador, a grande maioria dos temas apresentou redução em relação ao erro de inclusão, ou seja, menos pixels foram incluídos a temas em que, de fato, não deveriam estar. Assim, apenas o tema 4 e 6 não tiveram seus valores de erro de inclusão diminuídos com a utilização do classificador Fuzzy.

Em relação ao Índice Kappa, obteve-se o valor de 0,4688 para o mapeamento de cobertura do solo quando utilizada a Máxima Verossimilhança e 0,5418 para a classificação onde foi feito o uso do classificador Fuzzy. Ambas as classificações, segundo Landis e Koch (1977), são qualificadas como boas. O uso do classificador Fuzzy melhorou a classificação em 7,3%.




Figura 4.14 – Gráfico comparativo entre os erros de omissão obtidos na matriz do erro quando utilizada a classificação Fuzzy e a classificação pelo método da Máxima Verossimilhança quando utilizadas imagens do sensor AVNIR-2/ALOS.




Figura 4.15 – Gráfico comparativo entre os erros de omissão e inclusão obtidos na matriz do erro quando utilizada a classificação Fuzzy e a classificação pelo método da Máxima Verossimilhança quanto utilizadas imagens do sensor AVNIR-2/ALOS.

4.4.2 Cobertura do solo utilizando imagem do sensor CCD/CBERS-2

Analogamente a apresentação dos resultados do item 4.4.2, são aqui apontados os resultados intermediários à classificação Fuzzy utilizando imagens do sensor CCD/CBERS-2, bem com o produto final, o mapa de cobertura do solo.

Na Tabela 4.7 encontra-se a porcentagem dos temas nos polígonos amostrados, segundo a verdade terrestre na resolução do sensor CCD/CBERS-2 (Figura 4.5), para a confecção da matriz de partição Fuzzy encontrada, em seguida, na Tabela 4.8.

Tabela 4.7 – Área dos temas presentes nos polígonos de amostragem das áreas de treinamento para a elaboração da matriz de partição Fuzzy

Tema	1		2		3		4		5		6		7		8	
	área [m ²]	%	área [m ²]	%	área [m ²]	%	área [m ²]	%	área [m ²]	%	área [m ²]	%	área [m ²]	%	área [m ²]	%
1	5879	1	2100	1	-	-	-	-	-	-	-	-	-	-	-	-
2	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
3	-	-	-	-	2520	0,67	-	-	-	-	-	-	-	-	-	-
4	-	-	-	-	840	0,22	54595	0,98	-	-	-	-	-	-	-	-
5	-	-	-	-	420	0,11	-	-	12599	1	-	-	-	-	-	-
6	-	-	-	-	-	-	840	0,02	-	-	48296	1	-	-	-	-
7	-	-	-	-	-	-	-	-	-	-	-	-	14699	1	-	-
8	-	-	-	-	-	-	-	-	-	-	-	-	-	-	12599	1

Tabela 4.8 – Matriz de partição Fuzzy

IDR_ID	1	2	3	4	5	6	7	8
1	1	1	0	0	0	0	0	0
2	0	0	0	0	0	0	0	0
3	0	0	0,6667	0,2222	0,1111	0	0	0
4	0	0	0	0,9848	0	0,0152	0	0
5	0	0	0	0	1	0	0	0
6	0	0	0	0	0	1	0	0
7	0	0	0	0	0	0	1	0
8	0	0	0	0	0	0	0	1

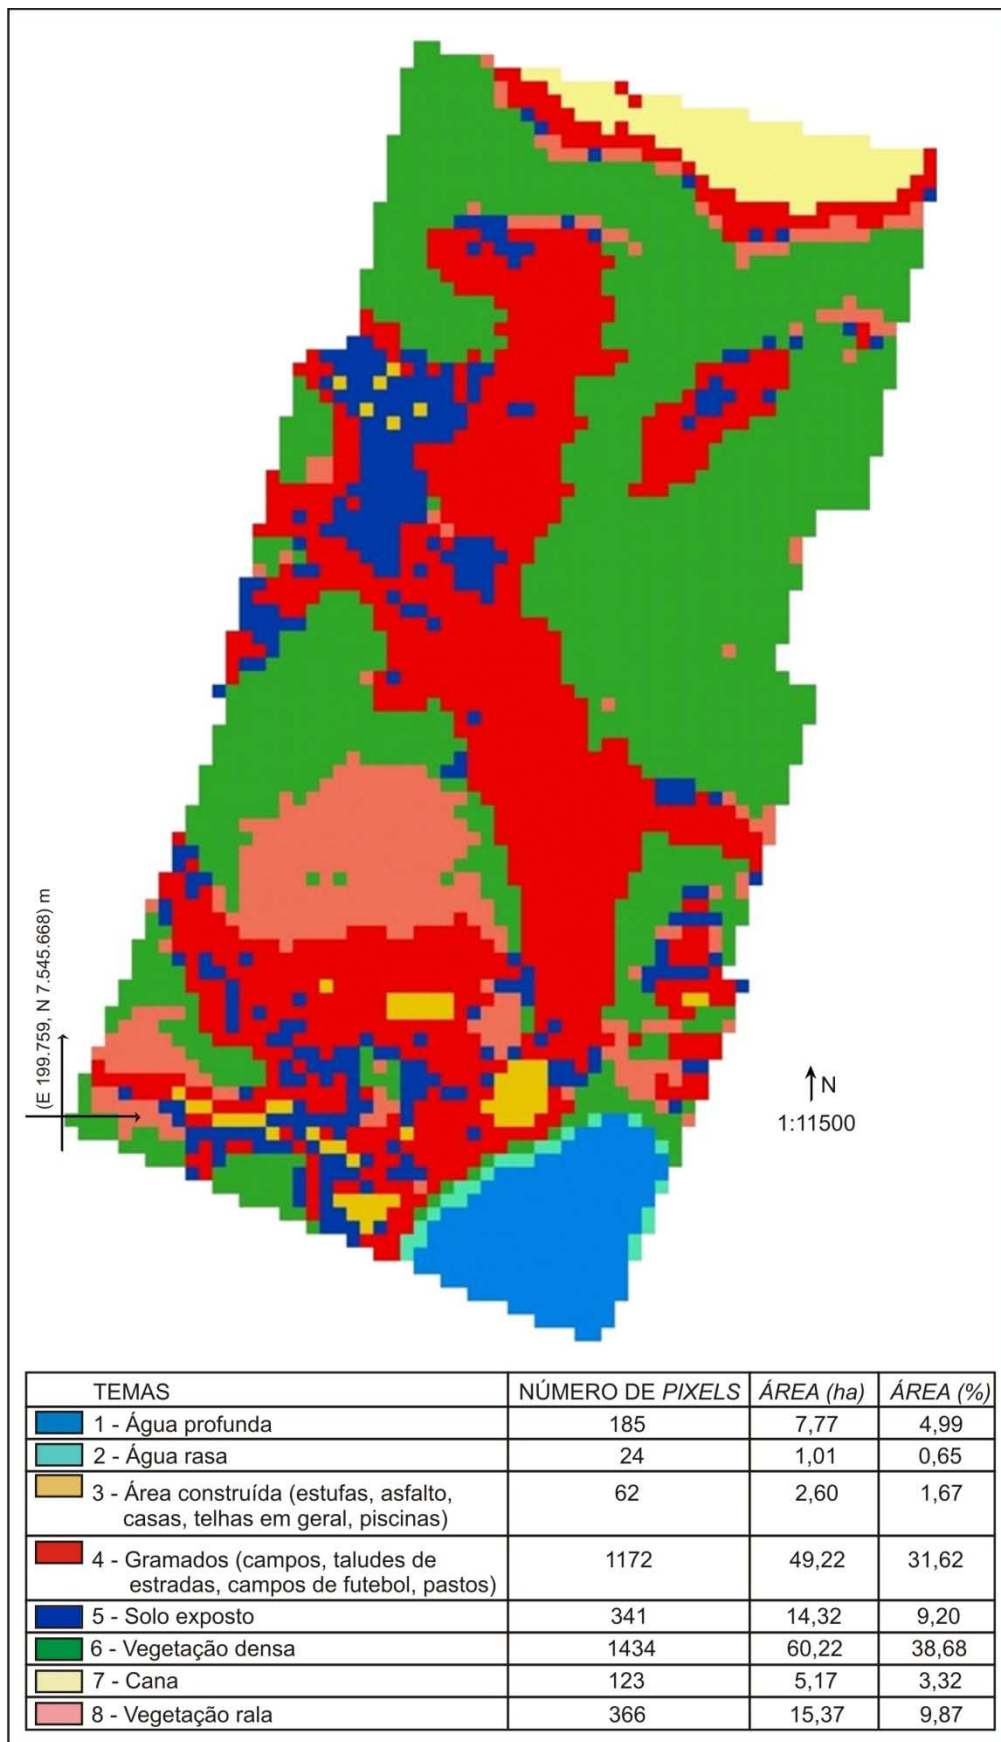


Figura 4.16 – Classificação Fuzzy para imagem CCD/CBERS-2.

Como visto, após a definição das novas assinaturas e aplicando as funções devidas, é obtido o mapa de cobertura do solo pela classificação Fuzzy (Figura 4.16) e a matriz do erro que avalia tal classificação encontram-se na Tabela 4.9. Foi possível avaliar as variações dos erros de omissão e inclusão através da análise das Figuras 4.17 e 4.18, provenientes da matriz do erro representada na Tabela 4.9 (avaliação da classificação Fuzzy) e Tabela XX (avaliação da classificação por Máxima Verossimilhança).

É cabível relatar que a classificação Fuzzy favoreceu a melhora da classificação dos pixels pertencentes às áreas de transição, permitindo uma transição gradual entre as classes de cobertura do solo.

Tabela 4.9 – Matriz do erro comparando o mapa de cobertura do solo baseado nas fotografias aéreas na resolução espacial do sensor CCD/CBERS-2 com o mapa de cobertura do solo das imagens do sensor CCD/CBERS-2 obtido através da classificação Fuzzy.

Tema \ Tema	1	2	3	4	5	6	7	8	Soma	ERRO DE INCLUSÃO
1	185	0	0	0	0	0	0	0	185	0
2	24	0	0	0	0	0	0	0	24	1
3	0	0	9	25	17	11	0	0	62	0,8548
4	10	13	7	735	75	282	3	47	1172	0,3729
5	1	0	8	142	105	82	0	3	341	0,6921
6	27	0	5	110	29	1193	0	68	1432	0,1669
7	0	0	0	7	12	1	103	0	123	0,1626
8	1	2	5	41	0	163	0	145	366	0,6038
Soma	248	15	34	1060	247	1732	106	263	3705	
ERRO DE OMISSÃO	0,2540	1	0,7353	0,3066	0,5749	0,3112	0,0283	0,4487		




Figura 4.17 – Gráfico comparativo entre os erros de omissão obtidos na matriz do erro quando utilizada a classificação Fuzzy e a classificação pelo método da Máxima Verossimilhança quando utilizadas imagens do sensor CBERS-2




Figura 4.18 – Gráfico comparativo entre os erros de inclusão obtidos na matriz do erro quando utilizada a classificação Fuzzy e a classificação pelo método da Máxima Verossimilhança quando utilizadas imagens do sensor CBERS-2.

Observando a Tabela 4.9 pode-se concluir que o tema 2 não apresentou pixels dentro do conjunto de polígonos amostrados para ele durante a coleta das áreas de treinamento, fato que contribuiu para reduzir a qualidade da classificação. Uma das justificativas para o ocorrido está no tamanho da faixa que compreende a água rasa, dificultando a amostragem do tema e sua visualização na composição colorida. Assim, os temas 2 (água rasa), 3 (Área construída) e 5 (solo exposto) foram os que apresentaram mais erros e os demais apresentaram classificação satisfatória.

Como anteriormente afirmado, é esperado que os erros de omissão gerados pela classificação Fuzzy (e, diga-se de passagem, os erros de inclusão) sejam menores que os erros gerados pela por Máxima Verossimilhança. Segundo apenas ao tema 6, esta afirmação se verifica. Os temas 1, 2 3 e 7 não sofreram alterações quanto ao erro de omissão para as duas classificações e, para os temas 4, 5 e 8 os erros de omissão na classificação Máxima Verossimilhança foram menores que na classificação Fuzzy.

No gráfico da Figura 4.18, relativo aos erros de inclusão, para os temas 1, 2 e 7 os valores para a classificação Fuzzy e por Máxima Verossimilhança não tiveram alterações. Entretanto, para os temas 3, 4 5 e 8 os erros de inclusão foram menores na classificação Fuzzy. Apenas para o tema 6 o erro de inclusão foi menor na classificação Máxima Verossimilhança. Verifica-se que, apesar das alterações nos erros de inclusão serem expressivas, os erros de omissão não sofreram melhoras quando utilizadas a classificação Fuzzy.

O Índice Kappa procedente da classificação por Máxima Verossimilhança foi de 0,5139 e o oriundo da classificação Fuzzy é de 0,5332. Através desde valores constata-se que a classificação Fuzzy obteve melhor resultado mesmo os erros de omissão não terem se comportado como esperado, ocorrendo uma compensação pela dos erros de inclusão. O

acréscimo na qualidade da classificação ao se fazer uso do classificador Fuzzy, nesse caso, foi de 2%.

4.4.3 Cobertura do solo utilizando imagem do sensor TM/LANDSAT-5

A Tabela 4.10 mostra os dados que deram origem a matriz de partição Fuzzy (Tabela 4.11), responsável pela obtenção do mapa de cobertura do solo (Figura 4.19) a partir de imagem do sensor TM/LANDSAT-5.

Tabela 4.10 – Área dos temas presentes nos polígonos de amostragem das áreas de treinamento para elaboração da matriz de partição Fuzzy.

Tema	1		2		3		4		5		6		7		8	
	área [m ²]	%	área [m ²]	%	área [m ²]	%	área [m ²]	%	área [m ²]	%	área [m ²]	%	área [m ²]	%	área [m ²]	%
1	23355	1	5390	1	-	-	-	-	-	-	-	-	-	-	-	-
2	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
3	898	0,2	-	-	-	-	3593	0,8	-	-	-	-	-	-	-	-
4	-	-	5390	0,21	-	-	18864	0,75	-	-	898	0,04	-	-	-	-
5	-	-	-	-	-	-	-	-	8084	1	-	-	-	-	-	-
6	-	-	-	-	-	-	-	-	-	-	30541	0,87	-	-	4491	0,13
7	-	-	-	-	-	-	4491	0,25	898	0,05	898	0,05	11678	0,65	-	-
8	-	-	-	-	-	-	5390	0,19	-	-	3593	0,13	-	-	18863	0,68

Tabela 4.11 – Matriz de partição Fuzzy

IDR_ID	1	2	3	4	5	6	7	8
1	1	1	0	0	0	0	0	0
2	0	0	0	0	0	0	0	0
3	0,2	0	0	0,8	0	0	0	0
4	0	0,21	0	0,75	0	0,04	0	0
5	0	0	0	0	1	0	0	0
6	0	0	0	0	0	0,87	0	0,13
7	0	0	0	0,25	0,05	0,05	0,65	0
8	0	0	0	0,19	0	0,13	0	0,68

A matriz do erro que avalia a classificação anterior, as variações dos erros de inclusão e omissão são exibidas na Tabela 4.12, Figura 4.20 e figura 4.21, respectivamente. Pode-se verificar, baseando-se na Figura 4.19, que dependendo do tamanho do alvo terrestre e da resolução espacial do sensor trabalhado, a fiel representação da paisagem pode não ser possível. Em relação aos erros de omissão e inclusão (Figuras 4.20 e 4.21), pode-se dizer, em primeiro momento, que os temas que apresentam seus alvos com tamanhos relativamente inferiores (2 e 3) tiveram os maiores erros. Temas mais homogêneos como “água profunda”, “cana” e “vegetação rala” já apresentaram erros menores. Verifica-se dificuldade para se classificar os temas 2 e 3, justificada pela

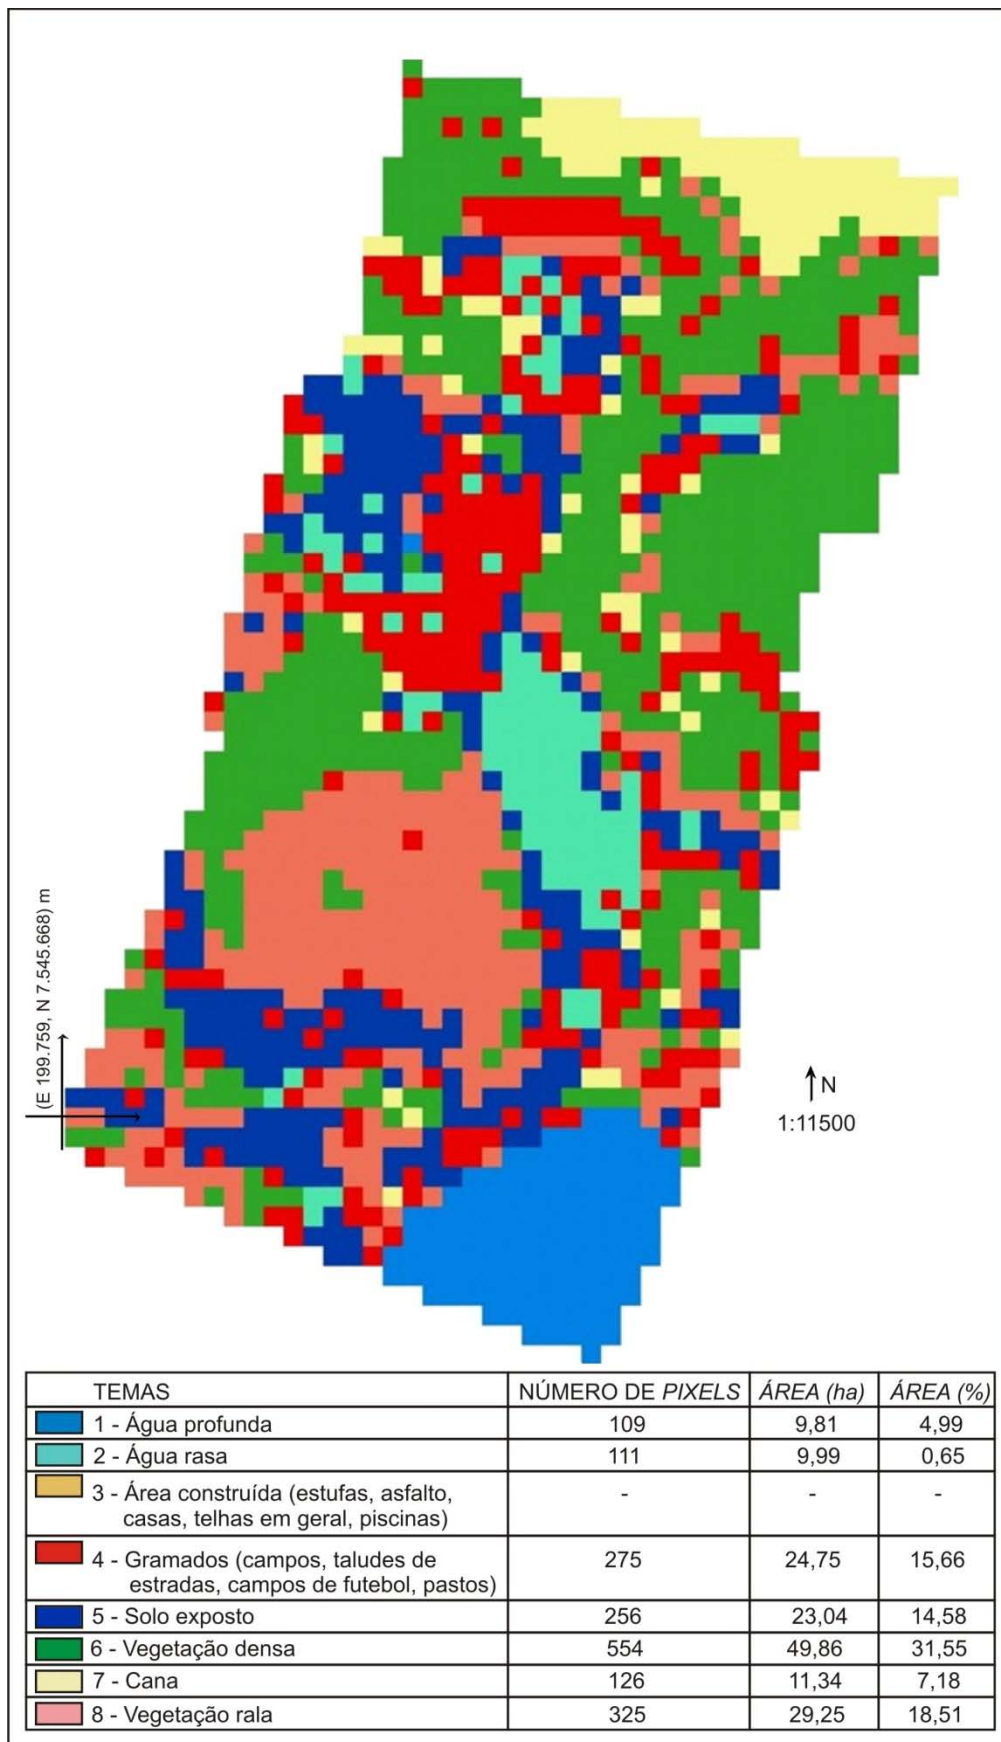


Figura 4.19 – Classificação Fuzzy para as imagem TM/LANDSAT-5.

heterogeneidade com que se apresentam e, aliada a baixa resolução espacial da cena do sensor TM/LANDSAT-5 (30 metros), os resultados foram comprometidos.

O Índice Kappa obtido para este mapeamento foi de 0,3927, possibilitando afirmar que ao ser aplicada a ferramenta Fuzzy, houve melhora dos resultados, uma vez que era de 0,3627 para a Máxima Verossimilhança e, portanto, segundo Landis e Koch (1977), a classificação é considerada boa. O incremento na qualidade da classificação foi de 3%.

Até o momento os resultados vêm sendo apresentados isoladamente, ressalvas as tabelas de erros de omissão e inclusão (comparando as classificações Máxima Verossimilhança e Fuzzy). No item seguinte serão comparados os três sensores, as classificações realizadas e feitas as discussões cabíveis.

Tabela 4.12 – Matriz do erro comparando o mapa de cobertura do solo baseado nas fotografias aéreas na resolução espacial do sensor TM/LANDSAT-5 com o mapa de cobertura do solo das imagens do sensor TM/LANDSAT-5 obtido através da classificação Fuzzy.

Tema \ Tema	1	2	3	4	5	6	7	8	Soma	ERRO DE INCLUSÃO
1	104	4	0	1	0	0	0	0	109	0,0420
2	0	0	0	91	8	12	0	0	111	1,0000
3	-	-	-	-	-	-	-	-	-	-
4	2	1	5	116	10	138	0	3	275	0,5782
5	0	0	5	145	48	55	0	3	256	0,8125
6	2	0	4	49	7	468	4	20	554	0,1641
7	0	0	1	22	6	50	47	0	126	0,6270
8	0	1	2	73	27	125	0	97	325	0,7015
Soma	108	6	17	497	106	848	51	123	1736	
ERRO DE OMISSÃO	0,0339	1,0000	1,0000	0,7666	0,5472	0,4597	0,0980	0,2114		




Figura 4.20 – Gráfico comparativo entre os erros de omissão obtidos na matriz do erro quando utilizada a classificação Fuzzy e a classificação pelo método da Máxima Verossimilhança quando utilizadas imagens do sensor TM/LANDSAT-5.




Figura 4.21 – Gráfico comparativo entre os erros de inclusão obtidos na matriz do erro quando utilizada a classificação Fuzzy e a classificação pelo método da Máxima Verossimilhança quando utilizadas imagens do sensor TM/LANDSAT-5.

4.5 Análises

As análises comparativas deste trabalho confrontam os mapas de verdade terrestre com os de cobertura do solo obtidos à partir de imagens dos sensores AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5, obtidos pelos métodos da Máxima Verossimilhança e Fuzzy.

4.5.1 Mapeamentos utilizando imagem do sensor AVNIR-2/ALOS

Na Figura 4.22 encontram-se: a) o mapa de cobertura do solo baseado em fotografias aéreas (verdade terrestre) na resolução espacial de 10 m, b) o mapa resultante da classificação por Máxima Verossimilhança a partir de imagem do sensor AVNIR-2/ALOS e c) o mapa de cobertura do solo obtido através do classificador Fuzzy para imagem do sensor AVNIR-2/ALOS.

Pode-se notar na classificação por Máxima Verossimilhança (Figura 4.22 b) uma expressiva confusão nas áreas de transição entre temas, o chamado efeito de borda, quando comparada com o mapa de cobertura do solo baseado na verdade terrestre (Figura 4.22 a). A classificação Fuzzy diminuiu consideravelmente este efeito, sendo facilmente visualizado na Figura 4.22 c.

No geral, pode-se concluir que o tema 1 foi bem classificado pelos dois operadores. A discrepância dos mesmos em relação ao mapa da verdade terrestre é pequena, mas

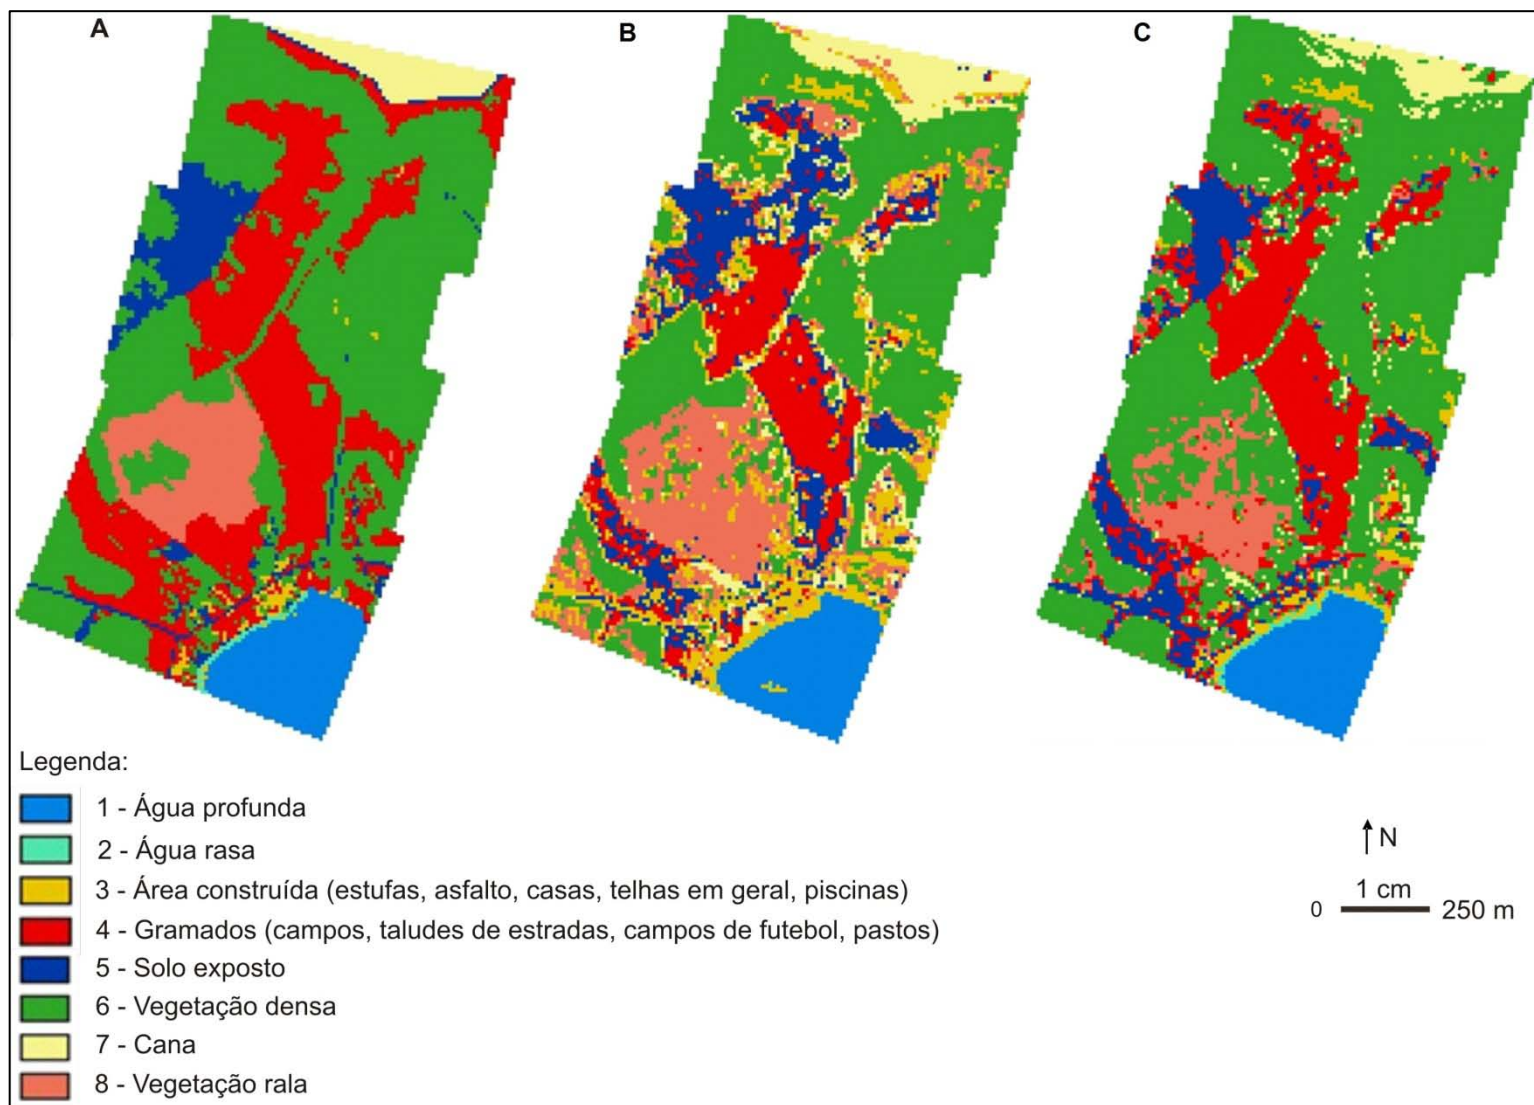


Figura 4.22 – (a) Mapa de cobertura do solo baseado nas fotografias aéreas na resolução do sensor AVNIR-2/ALOS, (b) Classificação pelo método da Máxima Verossimilhança para imagens do sensor AVNIR-2/ALOS e (c) Classificação Fuzzy, utilizando imagens do sensor AVNIR-2/ALOS.

mesmo assim o classificador Fuzzy apresentou maior exatidão. Houve grande confusão com relação aos temas 2 e 3. Por se tratar, o tema 3, de área urbanizada ou alvos urbanos, segundo Boschi e Galo (2007), devido às cidades constituírem ambientes heterogêneos, sua classificação apresenta maior grau de dificuldade com transições abruptas, independente do classificador utilizado. Assim, obviamente, como se observa neste trabalho, alguns classificadores possuem melhor desempenho que outros. Galo (2000) (citado por Boschi e Galo, 2007) salienta que dependendo da designação das classes, o que caracteriza esses ambientes urbanos é a ocorrência de classes misturadas, definindo uma continuidade nas áreas de transição entre elas (classes contínuas).

Em relação ao tema 4 (gramados - campos, taludes de estrada, campos de futebol, pasto), parte da grande omissão observada nos dois classificadores provavelmente se deve ao fato de que as fotografias aéreas coloridas (base para o mapa da verdade terrestre utilizado na comparação com os demais) não são da mesma data que a imagem do sensor AVNIR – 2 / ALOS utilizada neste trabalho, sendo estas datadas em 12/11/2006, estação chuvosa na região, e as fotografias obtidas em período seco, 13/05/2007. Aliás, pode-se estender também como justificativa aos erros apresentados pelos outros temas esta diferença nas datas.

O tema 7, cana, é observado apenas na região superior da área analisada como verificar-se no mapa de cobertura do solo baseado nas fotografias aéreas, porém, na classificação por Máxima Verossimilhança observou-se que este se confundiu expressivamente com o tema 6, vegetação densa. O efeito de borda é reduzido ao se aplicar o classificador Fuzzy. De uma forma geral, o mesmo acontece para os temas apresentados anteriormente.

Outra consideração importante está na amostragem dos temas vegetação densa (tema 6) e vegetação rala (tema 8). Verifica-se importante confusão entre esses dois temas, uma vez que apresentam os mesmos tipos de vegetação, diferindo na resposta espectral devido o espaçamento entre as árvores e/ou arbustos que possibilita a mistura de vegetação/solo exposto aos sensores utilizado.

Constata-se que a classificação Fuzzy melhorou a qualidade do mapa de cobertura do solo, uma vez que existe um mapa de verdade terrestre para servir como parâmetro. Também fica evidente esta melhoria, pois anteriormente foram analisados os índices Kappa das duas classificações.

4.5.2 Mapeamentos utilizando imagem do sensor CCD/CBERS-2

No que é pertinente aos resultados das classificações digitais utilizando-se: a) o mapa de cobertura do solo baseado nas fotografias aéreas (verdade terrestre) com resolução espacial de 20 m, b) o mapa de cobertura do solo utilizando imagem do sensor CCD/CBERS-2 por Máxima Verossimilhança e c) o mapa de cobertura do solo fundamentado nas imagens do sensor CCD/CBERS-2 utilizando o classificador Fuzzy – Figura 23 – percebe-se ligeira melhoria na classificação ao se utilizar o classificador Fuzzy.

Nota-se também que esta melhoria não ocorreu de forma tão perceptível como com as imagens do sensor AVNIR-2/ALOS (Figura 4.22) e, fundamentalmente, isto se procede visto o Índice Kappa. A diferença entre os valores de Kappa das classificações por Máxima Verossimilhança e Fuzzy para as imagens do sensor AVNIR-2/ALOS é maior que a diferença entre os índices obtidos quando usadas as imagens do CCD/CBERS-2. Em relação às áreas de amostragem, percebe-se que, pelo fato de não ter ocorrido melhoras substanciais, as áreas de treinamento foram satisfatoriamente definidas em concordância com a verdade terrestre, visto que ao serem comparadas com estas para a elaboração da matriz de partição Fuzzy, não apresentaram grandes divergências (fato comprovado também pela matriz de partição Fuzzy, Tabela 4.8). Em relação aos temas, também não apresentou boa classificação o tema 3 (área construída), assim como aconteceu na análise das classificações das imagens do AVNIR-2/ALOS. Isto se deve pela heterogeneidade com que se apresentam os alvos constituintes, dificultando a visualização (considerando a resolução do sensor 20 metros) e também a amostragem do mesmo em relação à data das imagens do sensor CCD/CBERS-2 e das fotografias, (constam períodos muito próximos, retirando a possibilidade de que seja motivo para comprometer a qualidade apresentadas para as classificações). Deve-se considerar também o efeito amostragem (degradação) do tamanho pixel, ou seja, quando feita a conversão dos vetores digitalizados para confecção do mapa de verdade terrestre com resolução espacial de 20 m.

É válida tal metodologia, uma vez que existe um mapa de verdade terrestre para servir como parâmetro, validando os resultados através de comparações analíticas os dados de referência (Justice et al., 2000).

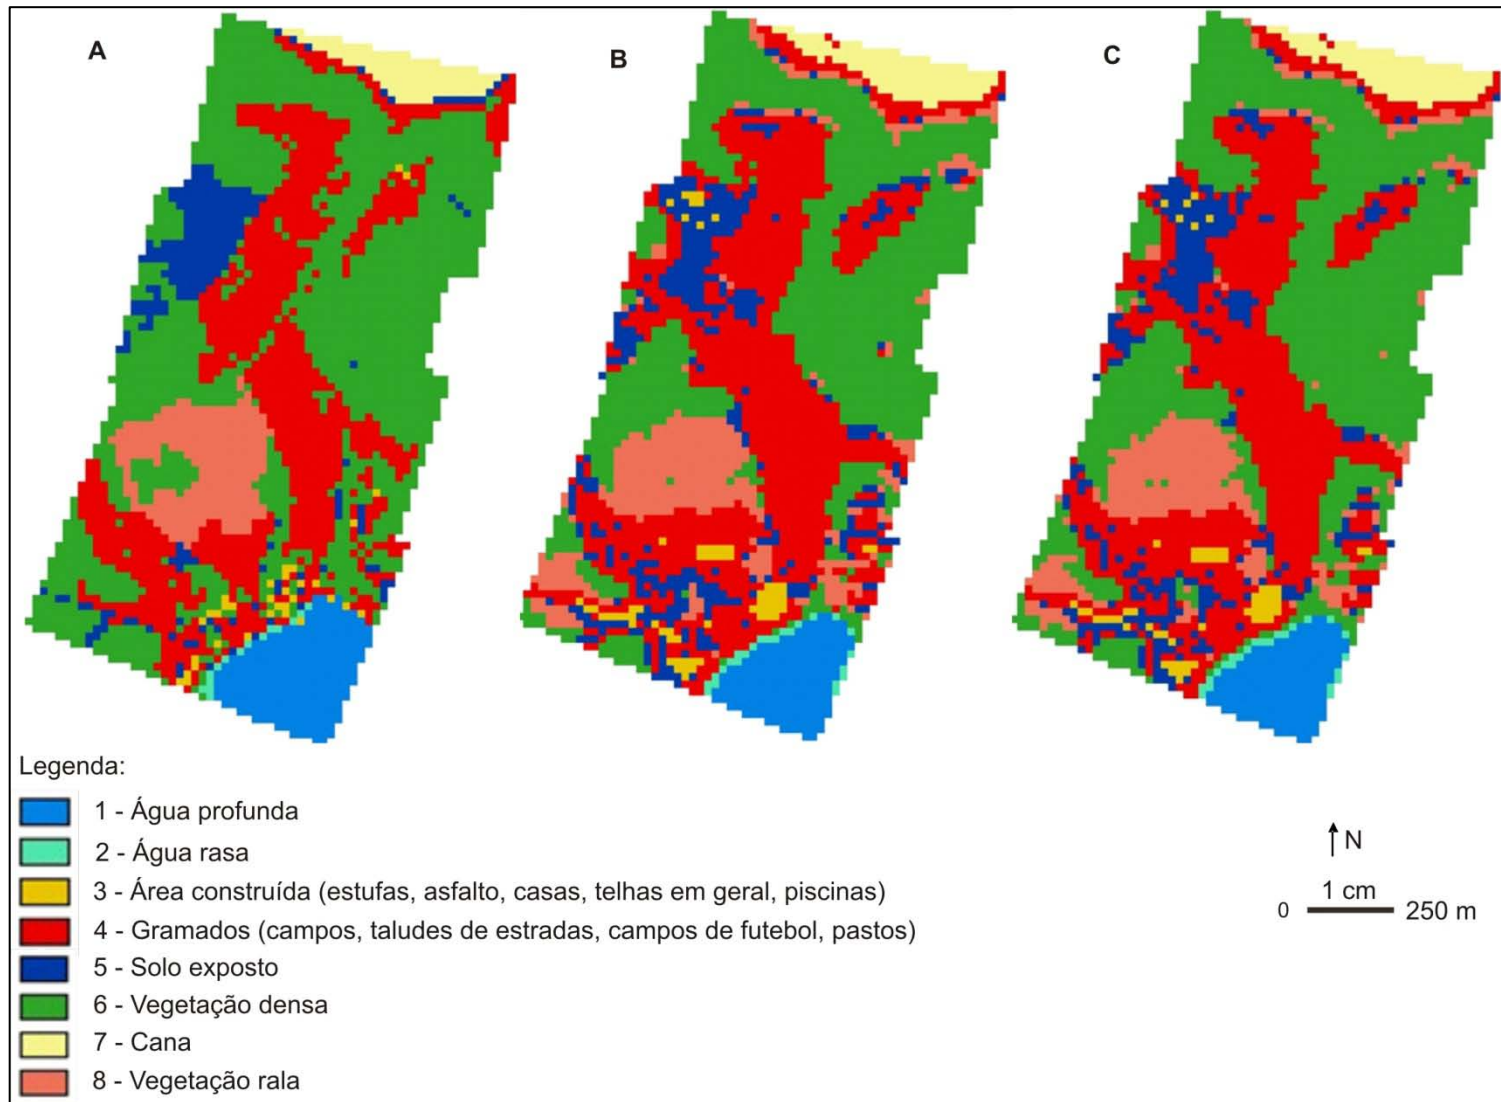


Figura 4.23 – (a) Mapa de cobertura do solo baseado nas fotografias aéreas na resolução do sensor CCD/CBERS-2, (b) Classificação pelo método da Máxima Verossimilhança para imagens do sensor CCD/CBERS-2 e (c) Classificação Fuzzy, utilizando imagens do sensor CCD/CBERS-2.

4.5.3 Mapeamentos utilizando imagem do sensor TM/LANDSAT-5

Quanto aos resultados utilizando imagem do sensor TM/LANDSAT-5, em relação à confusão entre os temas, fica nítida a classificação com qualidade comprometida. Entretanto, este trabalho compara apenas as diferenças dos dados sob o ponto de vista da resolução espacial e não considera, portanto, o mérito do à resolução espectral desse sensor.

O tema 3 é o mais comprometido por conta da extensão pequena da área e heterogeneidade dos seus alvos, confusão não justificável somente pela diferença das datas entre as imagens do sensor TM/LANDSAT-5 e as fotografias aéreas, uma vez que pertencem a mesma estação do ano, mas sim ao tamanho do pixel e dos alvos amostrados. Deve-se também ao fato dessa classe ter sido sub-amostrada no treinamento e por esta amostragem ter sido feita em áreas desfavoráveis.

O que acontece com os resultados utilizando as imagens do sensor TM/LANDSAT-5 é que a resolução de 30 metros, aliada ao tamanho do trecho trabalhado (1,561 Km²) e a especificidade dos temas (na qual o processo de classificação ainda é incumbido de separar 8 temas de cobertura de solo) permitem grandes confusões. Na Figura 4.24 podem-se notar as diferenças das duas classificações para com a verdade terrestre mostrada em (a). Temas como o da vegetação densa, cana, água profunda e vegetação rala foram bem classificados utilizando tanto a ferramenta Fuzzy quanto a MAXVER, porém, os demais detêm grandes confusões.

Sabe-se que a classificação Fuzzy utiliza os vetores da classificação por Máxima Verossimilhança que, ao serem sobrepostos na verdade terrestre, constata-se que nenhum dos polígonos coletados pertencem, de fato, ao tema 3, por isso a ausência do tema 3 no mapa de cobertura do solo quando se fez uso do classificador Fuzzy.

Verifica-se que a resolução espacial para se discriminar 8 temas em uma área relativamente pequena comprometeu os resultados finais, comprovando-se, assim como nos itens 4.5.1 e 4.5.2, que esta propriedade dos sensores tem influência direta na capacidade destes em discriminarem alvos terrestres.

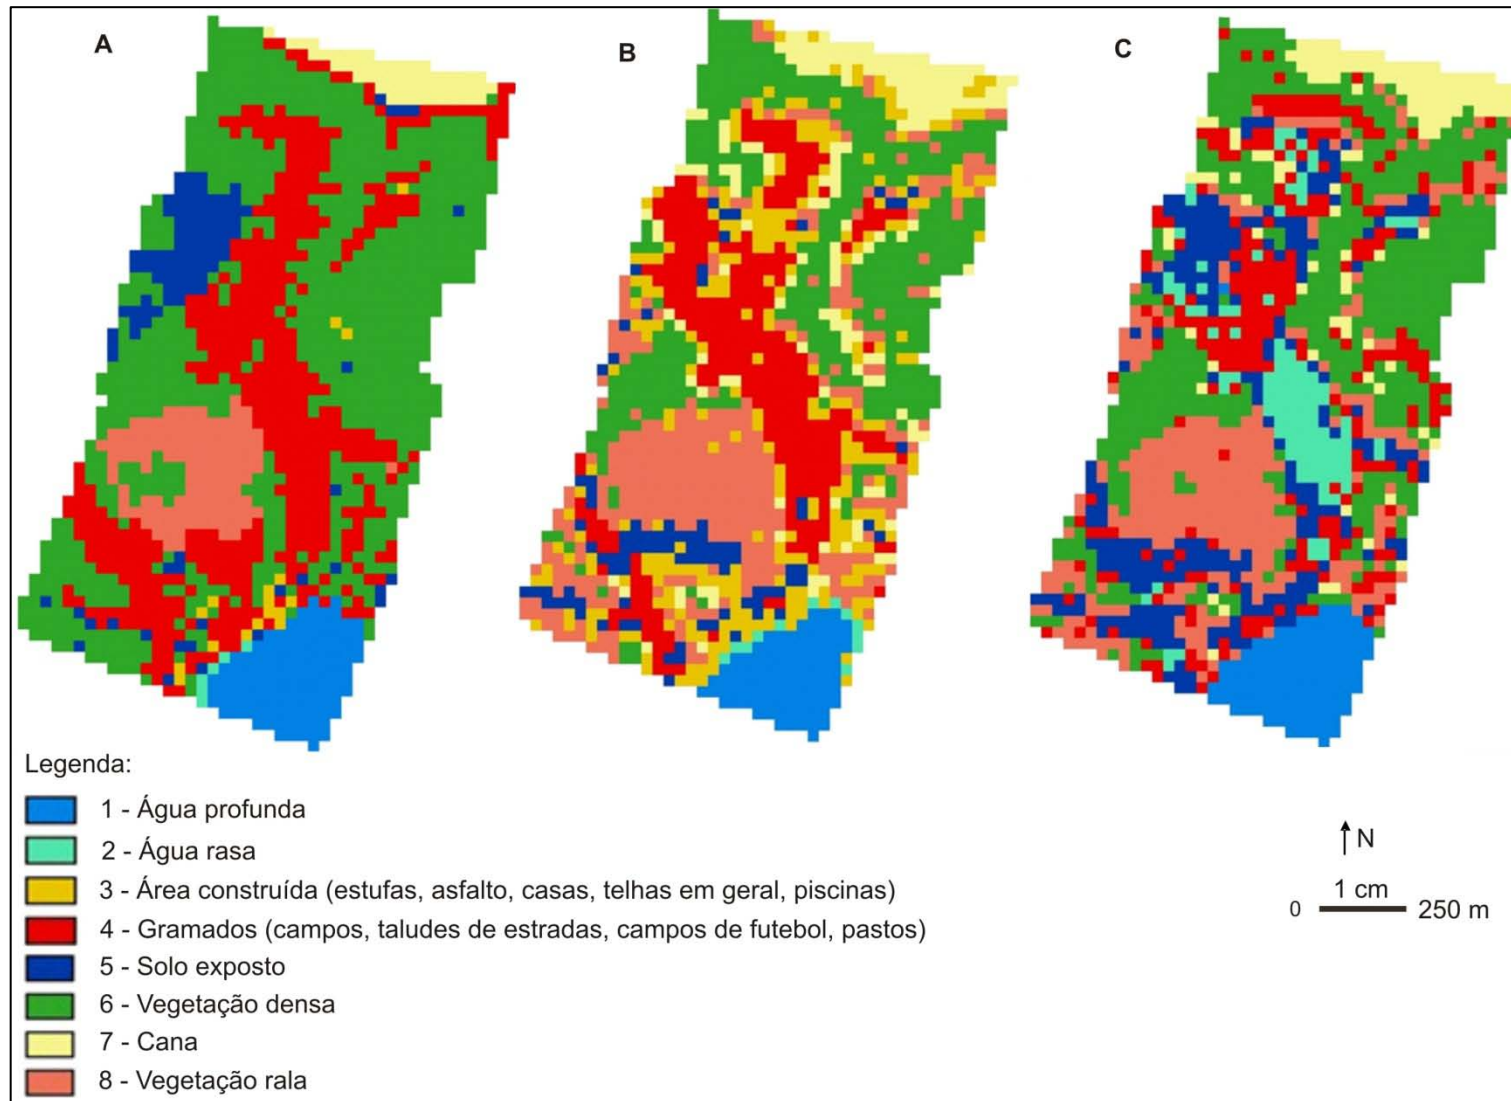


Figura 4.24 –(a) Mapa de cobertura do solo baseado nas fotografias aéreas na resolução do sensor TM/LANDSAT-5, (b) Classificação pelo método da Máxima Verossimilhança para imagens do sensor TM/LANDSAT-5 e (c) Classificação Fuzzy, utilizando imagens do sensor TM/LANDSAT-5.

4.5.4 Comparação quanto à área dos temas – Classificação por Máxima Verossimilhança

A Tabela 4.13 é a junção das matrizes do erro para as três classificações de cobertura do solo. Através dela pode-se perceber qual das classificações mais se aproximou da sua verdade terrestre. As Figuras 4.25 e 4.26 mostram esses resultados graficamente.

A primeira barra de cada tema (nas Figuras 4.25 e 4.26) corresponde à área que o tema apresenta na verdade terrestre. As demais barras se referem aos valores de áreas assumidas as confusões (nas classificações utilizando os sensores AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5) pelo tema na classificação Máxima Verossimilhança. Quanto mais as barras se aproximarem da barra da verdade terrestre, melhor é a sua classificação (Figura 4.26, em porcentagem). Percebe-se que os temas 1, 3, 5, 6 e 8 apresentaram-se mais próximos à verdade terrestre quando foi feito uso das imagens do senso AVNIR-2/ ALOS.

O ideal, no gráfico da Figura 4.25 (área real) seria que, por exemplo, para o tema 1 que apresenta na verdade terrestre 105.000 m^2 , ao ser classificado utilizando as imagens dos sensores AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5, o valor pouco se alterasse. Como isso não ocorre, no gráfico da Figura 4.26 encontra-se o quão se distancia cada tema da quando comparado à verdade terrestre (área proporcional). Em relação ao tema 1, pode-se afirmar para o sensor AVNIR-2/ALOS, do total de pixel que deveriam pertencer a este tema 1050 pixels, segundo a Tabela 4.1, 98% o fizeram, em se tratando da imagem do sensor CCD/CBERS-2, 75% dos pixels que deveriam ser tema 1 foram classificados corretamente e 80% ao se utilizar as imagens do sensor TM/LANDSAT-5. Para os demais temas, a interpretação é análoga.

Tabela 4.13 – Comparação entre as matrizes do erro dos sensores (Verdade T. = Verdade Terrestre; AR = Área Real [em m²]; AP = Área Proporcional [%]; NP = Número de Pixels)

Temas	Verdade T.	TEMA 1									TEMA 2									TEMA 3									
		AVNIR-2/ALOS			CCD/CBERS-2			TM/LANDSAT-5			AVNIR-2/ALOS			CCD/CBERS-2			TM/LANDSAT-5			AVNIR-2/ALOS			CCD/CBERS-2			TM/LANDSAT-5			
		NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	
1	105000	1	1025	0,98	102500	185	0,75	74000	94	0,80	84600	15	0,27	1500	0	0	0	0	0	0	8	0,05	800	0	0,00	0,00	0	0	0
2	5500	1	1	0	100	24	0,10	9600	14	0,12	12600	3	0,05	300	0	0	0	1	0,17	900	1	0,01	100	0	0,00	0,00	0	0	0
3	15000	1	24	0,02	2400	0	0	0	8	0,07	7200	37	0,67	3700	0	0	0	5	0,83	4500	87	0,58	8700	9	0,26	3600	6	0,35	5400
4	442800	1	0	0	0	17	0,07	6800	0	0	0	0	0	0	13	0,87	5200	0	0	0	16	0,11	1600	7	0,21	2800	1	0,06	900
5	104100	1	0	0	0	1	0	400	0	0	0	0	0	0	0	0	0	0	0	10	0,07	1000	9	0,26	3600	4	0,24	3600	
6	730600	1	0	0	0	18	0,07	7200	1	0,01	900	0	0	0	0	0	0	0	0	8	0,05	800	4	0,12	1600	2	0,12	1800	
7	45200	1	0	0	0	0	0	0,00	1	0,01	900	0	0	0	0	0	0	0	0	8	0,05	800	0	0,00	0	1	0,06	900	
8	109900	1	0	0	0	3	0,01	1200	0	0	0	0	0	0	2	0,13	800	0	0	0	12	0,08	1200	5	0,15	2000	3	0,18	2700
soma			1050	1	105000	0248	1	99200	118	1	106200	55	1	5500	015	1	6000	6	1	5400	0150	1	15000	34	1	13600	17	1	15300

TEMA 4									TEMA 5									TEMA 6											
AVNIR-2/ALOS			CCD/CBERS-2			TM/LANDSAT-5			AVNIR-2/ALOS			CCD/CBERS-2			TM/LANDSAT-5			AVNIR-2/ALOS			CCD/CBERS-2			TM/LANDSAT-5					
NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
1	0	100	0	0	0	0	0	0	2	0	200	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
551	0,12	55100	27	0,03	10800	96	0,19	86400	204	0,20	20400	20	0,08	8000	18	0,17	153	953	0,13	95300	11	0,01	4400	141	0,17	126900			
1509	0,34	150900	749	0,71	29960	151	0,30	135900	92	0,09	9200	75	0,30	30000	6	0,06	51	103	0,01	10300	336	0,20	134400	22	0,03	19800			
1031	0,23	103100	153	0,14	61200	103	0,21	92700	491	0,47	49100	113	0,46	45200	46	0,43	391	292	0,04	29200	109	0,06	43600	28	0,03	25200			
243	0,05	24300	76	0,07	30400	25	0,05	22500	52	0,05	5200	17	0,07	6800	5	0,05	42	4816	0,66	481600	1048	0,62	419200	386	0,47	347400			
447	0,10	44700	7	0,01	2800	34	0,07	30600	50	0,05	5000	12	0,05	4800	7	0,07	59	436	0,06	43600	1	0	400	82	0,10	73800			
646	0,15	64600	48	0,05	19200	88	0,18	79200	150	0,14	15000	10	0,04	4000	24	0,23	204	706	0,10	70600	191	0,11	76400	159	0,19	143100			
4428	1	442800	1060	1	42400	497	0	447300	1041	1	104100	247	1	98800	106	1	900	7306	1	730600	1696	1	678400	818	1	736200			

TEMA 7									TEMA 8								
AVNIR-2/ALOS			CCD/CBERS-2			TM/LANDSAT-5			AVNIR-2/ALOS			CCD/CBERS-2			TM/LANDSAT-5		
NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
25	0,06	2500	0	0	0	4	0,08	3600	96	0,09	9600	0	0	0	8	0,07	7200
2	0	200	3	0,03	1200	0	0	0	3	0	300	49	0,19	19600	0	0	0
5	0,01	500	0	0	0	0	0	0	3	0	300	8	0,03	3200	3	0,02	2700
0	0	0	0	0	0	0	0	0	188	0,17	18800	52	0,20	20800	16	0,13	14400
395	0,87	39500	103	0,97	41200	47	0,92	42300	28	0,03	2800	0	0	0	1	0,01	900
25	0,06	2500	0	0	0	0	0	0	781	0,71	78100	154	0,59	61600	95	0,77	85500
452	1	45200	106	1	42400	51	1	45900	1099	1	109900	263	1	105200	123	1	110700




Figura 4.25 – Distribuição das áreas de cada tema obtidas através da classificação Máxima Verossimilhança em metros quadrados.

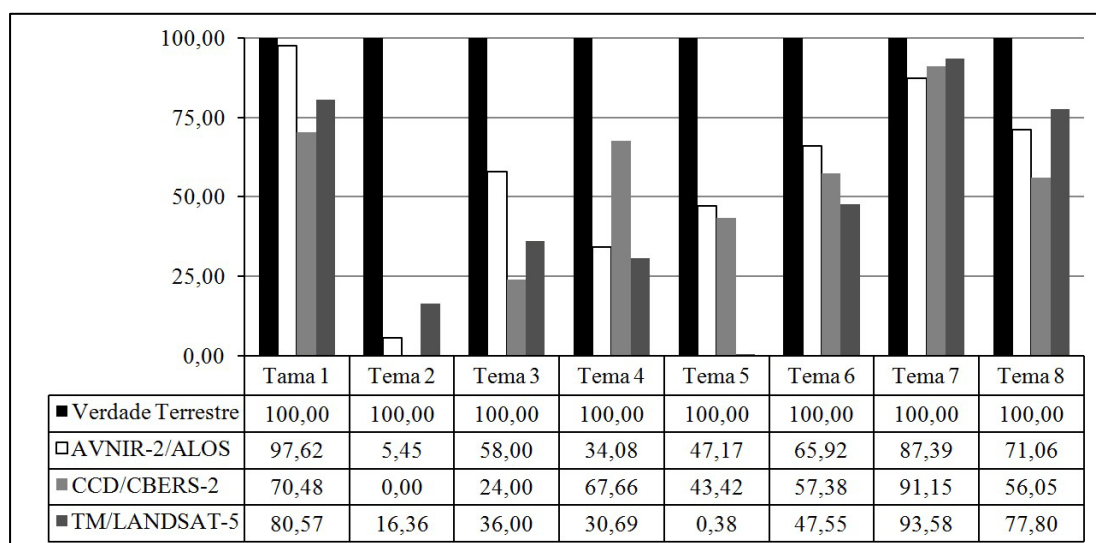


Figura 4.26 – Distribuição das áreas de cada tema obtidas através da classificação Máxima Verossimilhança em porcentagem.

Pode-se afirmar que a classificação obtida para a imagem do sensor AVNIR-2/ALOS é mais próxima da verdade terrestre, porém para o tema 4 e 7 o desempenho melhor foi quando utilizado o sensor CCD/CBERS-2. O sensor TM/LANDSAT-5 classificou melhor apenas o tema 8, por Máxima Verossimilhança. Verifica-se também que para os três sensores, os temas 2 e 3 apresentaram dificuldades para serem classificados.

4.5.5 Comparação quanto à área dos temas – Classificação Fuzzy

Ao se utilizar o classificador Fuzzy como complemento aos processos de classificação digital, são incorporados acertos principalmente no que diz respeito às áreas de transição. A superioridade quando utilizado o classificador Fuzzy é demonstrada em vários estudos (Islam, 2004), pois evita problemas associados às técnicas como da Máxima Verossimilhança, tornando-se um método potencial no que diz respeito à cobertura do solo.

Considerando os sensores AVNIR-2/ALOS e CCD/CBERS-2, os resultados obtidos foram nitidamente superiores, todavia, esperava-se também um desempenho nítido ao se aplicar o classificador Fuzzy nos dados referentes ao sensor TM/LANDSAT-5, também denotado pelos valores dos índices Kappa. A classificação Fuzzy para o TM/LANDSAT-5 não favoreceu o desempenho da classificação, uma vez que a resolução prejudicou a coleta dos polígonos de treinamento, fato também agravado ao se considerar uma área com relativa diversidade de temas com características físicas desfavoráveis (área principalmente).

Assim como para a classificação da Máxima Verossimilhança, foram convertidos os resultados das matrizes do erro em gráficos e tabelas. A Tabela 4.14 dá suporte com seus dados para a confecção dos gráficos exibidos nas Figuras 4.27 e 4.28. De forma mais detalhada, observa-se que a utilização do sensor AVNIR-2/ALOS para a elaboração da classificação da cobertura do solo mostrou-se favorável para os temas 1, 2, 3, 5, 6 e 8, ou seja, para a maioria dos temas. O destaque para se perceber a qualidade da classificação quando utilizadas imagens do sensor AVNIR-2/ALOS é o tema 2, o qual, por algumas vezes neste trabalho se afirmou que o fato de ser composto por alvos de tamanhos reduzidos, dificultaria a classificação, proporcionando confusões. O classificador Fuzzy, aliado a resolução espacial do sensor AVNIR-2/ALOS possibilitou que apenas 31% dos 1050 pixels (Tabela 4.1) não foram corretamente classificados. Na classificação convencional apenas 5% deles foram classificados devidamente.

Tabela 4.14 – Comparação entre as matrizes do erro dos sensores (Verdade T. = Verdade Terrestre; AR = Área Real [em m²]; AP = Área Proporcional [%]; NP = Número de Pixels)

Temas	Verdade T.		TEMA 1									TEMA 2									TEMA 3								
			AVNIR-2/ALOS			CCD/CBERS-2			TM/LANDSAT-5			AVNIR-2/ALOS			CCD/CBERS-2			TM/LANDSAT-5			AVNIR-2/ALOS			CCD/CBERS-2			TM/LANDSAT-5		
	AR	AP	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR
1	105000	1	1027	0,98	102700	185	0,75	74000	114	0,97	102600	8	0,15	800	0	0	0	4	0,67	3600	5	0,03	500	0	0	0	0	0	0
2	5500	1	11	0,01	1200	24	0,10	9600	0	0	0	38	0,69	3800	0	0	0	0	0	0	6	0,04	600	0	0	0	0	0	0
3	15000	1	0	0	1100	0	0	0	0	-	0	8	0,15	800	0	0	0	0	-	0	45	0,30	4500	9	0,26	3600	0	-	0
4	442800	1	0	0	0	10	0,04	4000	2	0,02	1800,0	1	0,02	100	13	0,87	5200	1	0,17	900	25	0,17	2500	7	0,21	2800	5	0,29	4500
5	104100	1	0	0	0	1	0	400	0	0	0	0	0	0	0	0	0	0	0	30	0,20	3000	8	0,24	3200	5	0,29	4500	
6	730600	1	0	0	0	27	0,11	10800	2	0,02	1800,0	0	0	0	0	0	0	0	0	27	0,18	2700	5	0,15	2000	4	0,24	3600	
7	45200	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3	0,02	300	0	0	0	1	0,06	900	
8	109900	1	0	0	0	1	0	400	0	0	0	0	0	2	0,13	800	1	0,17	900	9	0,06	900	5	0,15	2000	2	0,12	1800	
soma			1050	1	105000	248	1	99200	118	1	106200	55	1	550	15	1	6000	6	1	5400	150	1	15000	34	1	13600	17	1	15300

TEMA 4									TEMA 5									TEMA 6											
AVNIR-2/ALOS			CCD/CBERS-2			TM/LANDSAT-5			AVNIR-2/ALOS			CCD/CBERS-2			TM/LANDSAT-5			AVNIR-2/ALOS			CCD/CBERS-2			TM/LANDSAT-5					
NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR
0	0	0	0	0	0	1	0	900,00	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	200	0	0	0	91	0,18	81900	3	0	300	0	0	0	8	0,08	7200	2	0	200	0	0	0	12	0,01	10800			
67	0,02	6700	25	0,02	10000	0	-	0	44	0,04	4400	17	0,07	6800	0	-	0,00	207	0,03	20700	11	0,01	4400	0	-	0			
2187	0,49	218700	735	0,69	29400	116	0,23	104400	193	0,19	19300	75	0,30	30000	10	0,09	9000	400	0,05	40000	282	0,17	112800	138	0,17	124200			
632	0,14	63200	142	0,13	56800	145	0,29	130500	486	0,47	48600	105	0,43	42000	48	0,45	4320	172	0,02	17200	82	0,05	32800	55	0,07	49500			
881	0,20	88100	110	0,10	44000	49	0,10	44100	220	0,21	22000	29	0,12	11600	7	0,07	6300	6078	0,83	607800	119	0,70	477200	438	0,54	394200			
205	0,05	20500	7	0,01	2800	22	0,04	19800	26	0,02	2600	12	0,05	4800	6	0,06	5400	208	0,03	20800	1	0	400	50	0,06	45000			
454	0,10	45400	41	0,04	16400	73	0,15	65700	69	0,07	6900	0	0	0	27	0,25	2430	239	0,03	23900	163	0,10	65200	125	0,15	112500			
4428	1	442800	1060	1	42400	497	1	447300	104	1	104100	238	0,96	95200	106	1	9540	7306	1	730600	173	1,02	692800	818	1	736200			

TEMA 7									TEMA 8								
AVNIR-2/ALOS			CCD/CBERS-2			TM/LANDSAT-5			AVNIR-2/ALOS			CCD/CBERS-2			TM/LANDSAT-5		
NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR	NP	AP	AR
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	-	0	1	0	100	0	0	0	-	-	0
6	0,01	600	3	0,03	1200	0	0	0	26	0,02	2600	47	0,18	18800	3	0,02	2700
0	0	0	0	0	0	0	0	0	1	0	100	3	0,01	1200	3	0,02	2700
122	0,27	12200	0	0	0	4	0,08	3600	606	0,55	60600	68	0,26	27200	20	0,16	18000
323	0,71	32300	103	0,97	41200	47	0,92	42300	9	0,01	900	0	0	0	0	0	0
1	0	100	0	0	0	0	0	0	456	0,41	45600	145	0,55	58000	97	0,79	87300
452	1	45200	106	1	42400	51	1	45900	1099	1	109900	263	1	105200	123	1	110700




Figura 4.27 – Distribuição das áreas de cada tema obtidas através da classificação Fuzzy em metros quadrados.




Figura 4.28 – Distribuição das áreas de cada tema obtidas através da classificação Fuzzy em porcentagem.

Ainda em relação aos temas, o sensor CCD/CBERS-2 proporcionou melhor classificação para os temas 4 e 7 e o TM/LANDSAT-5 o tema 8. Pode-se perceber visivelmente que o classificador Fuzzy melhorou as classificações e, de forma geral, o sensor AVNIR-2/ALOS ainda apresentou resultados mais próximos à verdade terrestre. Entretanto, pode-se afirmar para os demais que os resultados forma satisfatórios, apenas comprometidos com o tamanho da área a ser estudada (ou pelo nível de detalhamento requerido) e sua resolução.

CAPÍTULO 5 - CONCLUSÕES

Em relação aos métodos utilizados, este trabalho mostra que ao se fazer uso do classificador Fuzzy, a qualidade das classificações digitais de cobertura do solo é favorecida. Para o método da Máxima Verossimilhança, verifica-se desempenho satisfatório, porém limitado por desconsiderar a formação heterogênea dos pixels. O classificador Fuzzy preenche tal lacuna, sendo utilizado para representar a cobertura vegetal quando pixels podem ter múltiplas ou parciais classes de adesão. Constatou-se que a abordagem Fuzzy, apesar de não ser trivial e utilizada tão amplamente como a classificação Máxima Verossimilhança, consiste em uma poderosa ferramenta para análise digital. Permite ainda constatar que os métodos de classificação devem ser utilizados de forma complementar, verificando-se esta melhora na classificação quando são integrados dois métodos.

Em relação aos sensores envolvidos, é fundamental exaltar que se ocupou neste trabalho em analisar somente a resolução espacial dos sensores utilizados, ficando, portanto, o sensor TM/LANDSAT-5, em desvantagem, uma vez que possui como mais vantajosa característica sua resolução espectral. Considerando então a resolução espacial, ao serem comparados mapas de cobertura do solo provenientes das imagens dos sensores AVNIR-2/ALOS, CCD/CBERS-2 e TM/LANDSAT-5 utilizando-se o Método da Máxima Verossimilhança, conclui-se que o sensor AVNIR-2/ALOS apresentou melhores resultados devido sua resolução espacial ser superior: 10 metros. Ao ser utilizado o classificador Fuzzy, verifica-se também que os melhores resultados foram obtidos pelo sensor AVNIR-2/ALOS, apresentando maior qualidade e fidelidade para com a verdade terrestre. Vale considerar, entretanto, que o sensor CCD/CBERS-2 atende com maiores vantagens a relação custo/benefício, uma vez tem suas cenas disponibilizadas gratuitamente e alcança resultados satisfatórios, muito próximos daqueles obtidos ao se fazer uso das cenas do sensor AVNIR-2/ALOS como visto neste trabalho.

Por fim, foi possível reafirmar que quanto maior a resolução espacial de um sensor, maior a sua capacidade em discernir alvos espectrais (maior a competência para distinguir geometricamente alvos terrestres). A acurácia dos mapeamentos de mapas de cobertura do solo deve ser avaliada para que os resultados dos mapeamentos sejam válidos e, ao se considerar o Índice Kappa como parâmetro de qualidade, é permitido o conhecimento da discrepância entre a situação retratada no mapa e a realidade.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADAMI, S. F. et al. Mapeamento da evolução dos usos e coberturas das terras na bacia do ribeirão Anhumas - Campinas (SP). Anais VIII Simpósio Brasileiro de Sensoriamento Remoto. Florianópolis: Brasil, 21-26 abr 2007, INPE, p. 5051-5058, 2007.
- AL ABBAS, A. H., SWAIN, P. H. E BAUMGARDNER M. F. Relating organic matter and clay content to multispectral radiance of soils. Soil Science. Baltimore, v. 114, p. 477– 485, 1972.
- ALLEN, A.; Environmental planning and management of the peri-urban interface: perspectives on an emerging field. Environmental and Urbanization. v. 15, n. 1, p. 135-148, 2003.
- ARSLAN, A.; KAYA, M. Determination of fuzzy logic membership functions. Fuzzy Sets and Systems v. 118, p. 297-306, 2001.
- BAUMGARDNER, M. F., S. J. KRISTOF, C. J. JOHANNSEN, AND A. L. ZACHARY. Effects of organic matter on the multispectral properties of soils. Proc. Indiana Acad. Science. v. 79, p. 413-422, 1970.
- BEZDEK, J. C.; EHRLICH, R.; FULL, W. FCM: the fuzzy c-means clustering algorithm. Computers and Geosciences, v. 10, n. 2-3, p. 191-203, 1984.
- BOLSTAD, PAUL V.; LILLESAND, T. M.; Rapid Maximum Likelihood Classification. Photogrammetric Engineering & Remote Sensing. v. 57, p. 67-74, 1990.
- BOLSTAD, P. V., E T. M. LILLESAND. Improved classification of forest vegetation in northern Wisconsin through a rule-based combination of soils, terrain, and Landsat Thematic Mapper data. Forest Science. v. 38. p. 5-20, 1992.
- BOSCHI, L. S.; GALO, M. L. B. T.; Análise da incerteza na representação de classes de cobertura do solo urbano resultantes da aplicação de uma rede neural artificial. Boletim de Ciências Geodésicas, sec. Artigos, Curitiba, v. 13, n. 1, p.22-41, jan-jun, 2007.
- BROWN H. E.; DIUK-WASSER M. A.; GUAN Y.; CASKEY S.; FISH D. Comparison of three satellite sensors at three spatial scales to predict larval mosquito presence in Connecticut wetlands. Remote Sensing of Environment, v. 112, p. 2301–2308, 2008.

- BURROUGH, P. A.; HEUVELINK, G. B. M. The sensitivity of boolean and continuous (Fuzzy) logical modelling to uncertain data. In European Conference and Exhibition on Geographical Information Systems Munich, 3. (EGIS'92). Munich, Germany, Proceedings: Munich, Germany: EGIS'92. p. 1032-1041, 1992.
- CÂMARA, G. et al. Introdução à Ciência da Geoinformação. São José dos Campos: INPE, 2005. Disponível em: <<http://www.dpi.inpe.br/gilberto/livro/introd/>>. Acesso em: 1 maio 2007.
- CAMPBELL, J. B. Introduction to remote sensing. New York: Guilford Press, 1987.
- CANTERS, F.; Evaluating the uncertainty of area estimates derived from Fuzzy land-cover classification. Photogrammetric Engineering and Remote Sensing, v. 63, n. 4, p. 403-414, 1997.
- CHENG, T.; MOLENAAR, M.; LIN H. Formalizing fuzzy objects from uncertain classification results. International Journal Geographical Information Science, v. 15, n. 1, p. 27-42, 2001.
- COHEN, J. A coefficient of agreement of nominal scales. Educational and Psychological Measurement, v.20, p. 37-46. 1960.
- CONGALTON, R.G.; GREEN, K. A practical look at sources of confusion in error matrix generation. Photogrammetric Engineering and Remote Sensing, v.59, n.5, p.641-644, 1993.
- DALMOLIN, R.S.D. Matéria orgânica e características físicas, químicas, mineralógicas e espectrais de Latossolos de diferentes ambientes. Porto Alegre, Universidade Federal do Rio Grande do Sul, 151p. (Tese de Doutorado), 2002.
- DEMATTE, J.A.M.; GARCIA, G.J. Alteration of soil properties through a weathering sequence as evaluated by spectral reflectance. Soil Science Society of America Journal, v.63, n.2, 1999.
- DI GREGÓRIO, A. Land cover classification system (LCCS), version 2: classification concepts and user manual. Rome: FAO, 2004.
- EASTMAN, J. R. IDRISI for Windows: Introdução e Exercício tutoriais. Tradução: Hasenack, H.; Weber, E. Porto Alegre: UFRGS, Centro de Recursos IDRISI, 240 p, 1998.
- EASTMAN, J R. IDRISI Andes: Guide to GIS and image processing. Manual version 15. Worcester: Clark University, 2006.
- EASTMAN, J. R.; Laney, R. M. Bayesian soft classification for sub-pixel analysis: a ed. San Diego: Elsevier, 2007.
- EIPHANIO, J. C. N.; LUIZ, A. J. B; FORMAGGIO, A. R. Crop area estimates using simple sampling scheme on satellite images. Bragantia, vol.61, no.2, p.187-197, 2002.

- FERREIRA, E.; DANTAS, A. A. A.; MORAES, A. R. Exatidão na classificação de fragmentos de matas em imagem do satélite Cbers-CCD, no município de Lavras, MG. Simpósio Brasileiro de Sensoriamento Remoto: Florianópolis, Brasil. INPE. p. 887-894. 2007.
- FIDALGO, E. C. Exatidão no processo de mapeamento temático da vegetação de uma área de Mata Atlântica no Estado de São Paulo a partir de imagens TM. 167 p. (INPE-5944-TDI/570). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 1995.
- FIGUEIREDO, G. C.; BRAGA, A. L.; ELOI, F. H.; CARVALHO, A. S.; CALIJURI, M. L. Caracterização da fragilidade ambiental utilizando Sistema de Informações Geográficas, Congresso Brasileiro de Cadastro Técnico Multifinalitário, UFSC Florianópolis, 2006.
- FISHER P.F.; PATHIRANA S. The Evaluation of Fuzzy Membership of Land Cover in the Suburban Zone, *Remote Sensing of Environment*, v. 34, p. 121-132, 1990.
- FLORENZANO, T. G. Imagens de satélite para estudos ambientais. São Paulo: Oficina de Textos, 2002.
- FOODY, G. M. A fuzzy sets approach to the representation of vegetation continua from remotely sensed data: an example from lowland heath. *Photogrammetric Engineering and Remote Sensing*, v. 58, n. 2, p. 221-225, 1992.
- FOODY G. M., COX, D. P. Sub-pixel land cover composition estimation using a linear mixture model and fuzzy membership functions. *International Journal of Remote Sensing*, vol. 15, no. 3, p. 619-631, 1994.
- FOODY, G. M.; MCCULLOCH, M. B. & YATES, W. B. Classification of Remotely Sensed Data by an Artificial Neural Network: Issues Related to Training Data Characteristics. *Photogrammetric Engineering & Remote Sensing*. v. 61, n.4, p. 391-401, 1995.
- FOODY, G. M. Approaches for the production and evaluation of fuzzy land cover classifications from remotely-sensed data. *International Journal of Remote Sensing*, v. 17, n. 7, p. 1317-1340, 1996.
- FOODY G. M. The continuum of classification fuzziness in thematic mapping. *Photogrammetric Engineering and Remote Sensing*. p. 443 – 451; 1999.
- FOODY, G. M. GIS: the accuracy of spatial data revisited. *Progress in Physical Geography*, v. 25, n. 3, p. 389-398, 2001.
- FOODY, G. M. Classification accuracy comparison: Hypothesis tests and the use of confidence intervals in evaluations of difference, equivalence and non-inferiority. *Remote Sensing of Environment*, v. 113, p. 1658-1663, 2009.
- FOSCHI, P.G., AND D.K. SMITH. Detecting subpixel woody vegetation in digital imagery using two artificial intelligence approaches, *Photogrammetric Engineering and Remote Sensing*, 63(5): 493-500, 1997.

- GALO, M. L. B. T. Aplicação de redes neurais artificiais na classificação de dados de Sensoriamento Remoto: Relatório de projeto de pesquisa referente ao triênio 29/07/97 a 28/07/00. Presidente Prudente, FCT/Unesp, 2000.
- GAO, J., & LIU, Y. Mapping land degradation from space: A comparative study of Landsat ETM+ and ASTER data. *International Journal of Remote Sensing*, v. 29, p. 4029–4043, 2008.
- GOMES, G. J.; CUNHA, S. F.; GARCIA, C. J. Uso de técnicas de geoprocessamento no zoneamento de áreas de risco de escorregamento em Ouro Preto – MG. *Anais XIII Simpósio Brasileiro de Sensoriamento Remoto*. Florianópolis: INPE, 2007.
- GOPAL, S.; WOODCOCK, C. Theory and methods for accuracy assessment of thematic maps using Fuzzy sets. *Photogrammetric Engineering and Remote Sensing*, v. 60, n. 2, p. 181-188, 1994.
- HOGAN, D. J.; Mobilidade Populacional, sustentabilidade ambiental e vulnerabilidade social. *Revista Brasileira de estudos Populacionais*, v. 2., p. 323-338, 2005.
- IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Estimativas de População. Disponível em: < <http://www.ibge.gov.br/home/estatistica/populacao/contagem2007/SP.pdf> >. 2008. Acesso em jul. 2008. 2008.
- INPE – INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. Catálogo de Imagens CBERS. 2007. Disponível em: < <http://www.dgi.inpe.br/CDSR/>>. Acesso em: 01 mar. 2007.
- ISLAM, Z.; Fractals and Fuzzy sets for modelling the heterogeneity and spatial complexity of urban landscapes using multiscale remote sensing data. 220 f. Tese (Doutorado) – Department of Spatial Sciences, Curtin University of Technology, Perth, 2004.
- JAXA – EARTH OBSERVATION RESEARCH CENTER. Satellite ALOS - Advanced Land Observing Satellite. Disponível em < <http://www.eorc.jaxa.jp/ALOS/index.htm> >. Acesso em 03 de dezembro de 2008. 2008.
- JENSEN, J. R. *Introductory digital image processing: a remote sensing perspective*. 2. ed. New Jersey: Prentice Hall, 1996.
- JENSEN, J. R. *Remote sensing of the environment: an earth resource perspective*. New Jersey: Prentice Hall, 2000.
- JUNQUEIRA, C. S.; SILVA, E. P.; SCHULER, C. A. B.; JERUSALINSKY, L.; Avaliação do NDVI/CBERS-2 – CCD em Mata Atlântica na identificação de áreas ocupáveis de *Callicebus coimbrai* no litoral sul do Estado de Sergipe. *Anais XIV Simpósio Brasileiro de Sensoriamento Remoto*, Natal, Brasil, p. 2049–2056. Disponível em: < <http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.17.20.35.45/doc/2049-2056.pdf> >. Acesso em julho 2009. 2009.

- JUSTICE, C., BELWARD, A., MORISETTE, J., LEWIS, P., PRIVETTE, J., & BARET, F. Developments in the 'validation' of satellite sensor products for the study of the land surface. *International Journal of Remote Sensing*, v. 21, n. 17, p. 3383–3390, 2000.
- KARKI, T. K. Challenges of managing a government town planning office in Nepal: a planner's experience. *Environment and Urbanization*. 2004.
- KORMAN, V. Proposta de interligação das glebas do Parque Estadual de Vassununga (Santa Rita do Passa Quatro, SP). 2003. 135p Dissertação (Mestrado em Ecologia) - Escola Superior de Agricultura "Luis de Queiroz", Universidade de São Paulo, Piracicaba. 2003.
- LABA, M. et al. Conventional and Fuzzy accuracy assessment of the New York Gap Analysis Project land cover map. *Remote Sensing of Environment*, v. 81, p. 443-455, 2002.
- LANDIS J. R. E KOCK G. G. The measurement of observer agreement for categorical data. *Biometrics*, v 33, p. 159-74, 1977.
- LEGUIZAMÓN, S. et al. Unsupervised fuzzy c-means classification for the determination of dynamically homogeneous areas. In: Congresso Brasileiro de Sensoriamento Remoto, 8., Salvador. Anais XIII Simpósio Brasileiro de Sensoriamento Remoto Salvador: INPE, 1996.
- LILLESAND, T. M. E KIEFER, R. W.; *Remote Sensing and Image Interpretation*. New York, Chichester, Brisbane, Toronto, Singapore: Wiley. Third Edition. 1994.
- LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. *Remote sensing and image interpretation*. 5 ed. New York: John Wiley & Sons, 2004.
- LIMA JR. S. O. Análise de pontos por função Fuzzy. Dissertação de Mestrado. Informática aplicada (Fundação educacional Edson Queiroz). 2002.
- LIU, X. H.; SKIDMORE, A. K.; OOSTEN, H. V.. Integration of classification methods for improvement of land-cover map accuracy. *Journal of Photogrammetry & Remote Sensing*; v. 56, p. 257– 268; 2002.
- MACTEZUMA, P. Community - basead organization and participatory planning in south-east Mexico city. *Environmental and Urbanization*. 2001.
- MAGALHÃES, M. H.; Estudo ambiental para seleção de áreas para implantação de aterros sanitários com recuperação de energia na Bacia do Rio Sapucaí. Dissertação de Mestrado – Programa de Pós-graduação em Engenharia da Energia. Universidade Federal de Itajubá. 100 p.; 2007.
- MASELLI, F., CONESE, C., & PETKOV, L. Use of probability entropy for the estimation and graphical representation of the accuracy of maximum likelihood classifications. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 49, p. 13– 20, 1994.

- MATSUYAMA, T.; Knowledge-based aerial image understanding systems and expert systems for image processing. *Transactions on Geoscience and Remote Sensing*, v. 25, n. 3, p. 305–316; 1987.
- MOREIRA F. R. S.; Uso e avaliação de técnicas de integração e análise espacial em pesquisa mineral aplicadas ao planalto de Poços de Caldas. Dissertação de Mestrado em Sensoriamento Remoto. Instituto Nacional de Pesquisas Espaciais, 2002.
- MOREIRA, M. A. Fundamentos do sensoriamento remoto e metodologias de aplicação. São José dos Campos: 2001.
- NISHIYAMA, L.; Mapeamento Geotécnico preliminar da quadrícula de São Carlos, SP. Tese USP/FFLCH. Doutorado em Geografia Física. São Paulo. 1991.
- NOVO, E. M. L. M. Sensoriamento Remoto - Princípios e Aplicações. São José dos Campos: Edgard Blucher. Segunda edição. 308 p.. 1992.
- NOVO, E. M. L. M. Sensoriamento Remoto - Princípios e Aplicações. São José dos Campos: Edgard Blucher. Terceira edição. 363 p.. 2008.
- NUMATA, M., et al. Preparation of a sulfoxide group and ammonium-salt bonded silica stationary phase for separation of polychlorinated biphenyls from mineral oils. *J. Chromatogr. A*, 1210, p. 68-75, 2008.
- PEDRYCZ W.; GOMIDE, F.; An introduction to Fuzzy sets: analysis and design. New York: MIT Press, 1998.
- PINHO, C. M. D.; KUX, H. H.; ALMEIDA, C. M.; Elaboração de rede semântica para classificação de cobertura do solo de ambientes intra-urbanos: o Caso de São José dos Campos – SP; Simpósio Brasileiro de Sensoriamento Remoto: Florianópolis, Brasil. INPE. p. 637 - 644. 2007.
- PONZONI, F. J.; SHIMABUKURO, Y. E.; Sensoriamento Remoto no Estudo da Vegetação. São José dos Campos, SP: A. Silva Vieira Ed., 2007.
- PRADO, F. A. Sistema hierárquico de classificação para mapeamento da cobertura da terra nas escalas regional e urbana. Dissertação de Mestrado. Programa de Pós-Graduação em Ciências Cartográfica, Faculdade De Ciências e Tecnologia. Universidade Estadual Paulista, Campus de Presidente Prudente/SP. 2009.
- RICHARDS J. A. E JIA X.; Remote Sensing digital images analyses: an introduction. [Livro]. - New York : Springer-Verlag, 1999.
- RODRIGUES, T. R. I.; Rocha, A. M.; Filho, A. P.; Mapeamento do Uso e Cobertura das Terras na bacia do Baixo Curso do rio São José dos Dourados-SP por sistemas de informações geográfica e imagens de satélite. Anais XIII Simpósio Brasileiro de Sensoriamento Remoto. Florianópolis: INPE; 2007.
- ROSENFELD, G. H.; FITZPATRICK-LINS, K.; A coefficient of agreement as a measure of thematic classification accuracy. *Photogrammetric Engineering and Remote Sensing*, v. 52, p. 223 – 227, 1986.

- RUDORFF, B. F. T.; MELLO, M. P.; Shimabukuro, Y. E. Imagens de satélites de sensoriamento remoto no Brasil. Anais 2º Simpósio de Geotecnologias no Pantanal, Corumbá, 7-11 novembro 2009, Embrapa Informática Agropecuária/INPE, p.1077-1083, 2009.
- SCHOWENGERDT, R. A.; Remote Sensing, Models and Methods for Image Processing; p.135 a 150, Academic Press, 1997.
- SETTLE, J.J., DRAKE, N.A. Linear mixing and the estimation of ground cover proportions. International Journal of Remote Sensing 14, 1159-1177. 1993.
- SOUZA, C. C. et al. Técnicas de Sensoriamento remoto como subsídio ao estudo de florestas implantadas no Brasil - Uma revisão bibliográfica. Ciência Florestal. Santa Maria: Universidade Federal de Santa Maria, v. 17. 2007.
- STEFFEN, C. A.; GAMA, F. F. E NOVO, E. M. L. M.; Teste operacional de aquisição de dados aerotransportados - SADA, o experimento de Barra Bonita. São José dos Campos: INPE, 1992.
- SULSOFT LTDA. Satélite ALOS – Sensor AVNIR-2. Disponível em < www.sulsoft.com.br > .Acesso em 01 mai 2007.
- TEODORESCU, H. N., KANDEL, A. AND SCHNEIDER, M. Fuzzy Modeling and Dynamics. Fuzzy Sets and Systems, vol. 106, 1999.
- TUNDISI J. G. et al. Uso atual e uso potencial do solo no município de São Carlos,SP - base do planejamento urbano e rural [Relatório] : Relatório final de Projeto de Políticas Públicas da FAPESP.São Carlos : Suprema - Gráfica e Editora Ltda, 2005.
- USGS – United States Geological Service – USGS. Landsat Missions. 2009. Disponível em 01 jan. 2009.
- VENTURIERI, A.; SANTOS, J. R. Técnicas de Classificação de imagens para análise da cobertura vegetal. In: ASSAD, E. D.; SANO, E. E., eds. Sistema de Informações Geográficas: Aplicações em Agricultura. Brasília, Embrapa-SPI/Embrapa-CPAC. Cap. 18, p. 351-71, 1998.
- WANG, F.; HALL, B. G. Fuzzy representation of geographical boundaries in GIS. International Journal Geographical Information Systems, v. 10, n. 5, p. 573-590, 1996.
- WANG, F.; Improving remote sensing image analysis through Fuzzy information representation. Photogrammetric Engineering and Remote Sensing, v. 56, n. 8, p. 1163- 1169, 1990b.
- WANG, F.; Fuzzy supervised classification of remote sensing images. Geoscience and Remote Sensing, v. 28, n. 2, p. 194-201, 1990a.
- WOODCOCK, C. E.; STRAHLER, A. H. AND JUPP, D. L. B. The use of Variograms in Remote Sensing: I. Scenes Models and Simulated Images. Remote Sensing of Environment, Vol. 25, n. 3, p. 323 – 348, 1988a.

- WOODCOCK, C. E.; STRAHLER, A. H. AND JUPP, D. L. B. The use of Variograms in Remote Sensing: II. Real Images. Remote Sensing of Environmental, Vol. 25, n. 3, p. 349 – 397, 1988b.
- ZADEH L. A.; Fuzzy sets [Artigo] // Information Control. - 1965.
- ZEILHOFER, PETER; Sensoriamento Remoto [Livro], 2000.
- ZHANG, J; FOODY, G. M. Fully-fuzzy supervised classification of sub-urban land cover from remotely sensed imagery: statistical and artificial neural network approaches. International Journal of Remote Sensing, v. 22, n. 4, p. 615-628, 2001.
- ZHANG, J; STUART, N. Fuzzy methods for categorical mapping with image-based land cover data. International Journal Geographical Information Science, v. 15, n. 2, p. 175-195, 2001.
- ZUQUETTE L. V. Mapeamento Geotécnico preliminar na região de São Carlos. Dissertação de Mestrado da EESC/USP. 1981.