

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**AVALIAÇÃO DE IMAGENS DE SATÉLITE DE ALTA E
MUITO ALTA RESOLUÇÃO ESPACIAL PARA A
DISCRIMINAÇÃO DE CLASSES DE USO E OCUPAÇÃO
DO SOLO: APLICAÇÃO AO CASO DA SUB-BACIA DO
CÓRREGO CAPÃO COMPRIDO NO DISTRITO FEDERAL**

SIMONELI CARDOSO FERNANDES

ORIENTADOR: NABIL JOSEPH EID

**DISSERTAÇÃO DE MESTRADO EM TECNOLOGIA AMBIENTAL E
RECURSOS HÍDRICOS**

PUBLICAÇÃO: PTARH.DM - 079/05

BRASÍLIA/DF: JULHO-2005

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**AVALIAÇÃO DE IMAGENS DE SATÉLITE DE ALTA E MUITO
ALTA RESOLUÇÃO ESPACIAL PARA A DISCRIMINAÇÃO DE
CLASSES DE USO E OCUPAÇÃO DO SOLO: APLICAÇÃO AO
CASO DA SUB-BACIA DO CÓRREGO CAPÃO COMPRIDO NO
DISTRITO FEDERAL**

SIMONELI CARDOSO FERNANDES

**DISSERTAÇÃO SUBMETIDA AO DEPARTAMENTO DE
ENGENHARIA CIVIL E AMBIENTAL DA FACULDADE DE
TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA COMO PARTE
DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU
DE MESTRE EM TECNOLOGIA AMBIENTAL E RECURSOS
HÍDRICOS.**

APROVADA POR:

**PROF. NABIL JOSEPH EID, DOUTOR (ENC-UnB)
(Orientador)**

**PROF. NÉSTOR ALDO CAMPANA, DOUTOR (ENC-UnB)
(Examinador Interno)**

**PROF. ÁLVARO PENTEADO CRÓSTA, DOUTOR (IG-UNICAMP)
(Examinador Externo)**

BRASÍLIA/DF, 01 DE JULHO DE 2005.

FICHA CATALOGRÁFICA

FERNANDES, SIMONELI CARDOSO

Avaliação de Imagens de Satélite de Alta e Muito Alta Resolução Espacial para a Discriminação de Classes de Uso e Ocupação do Solo: Aplicação ao caso da sub-bacia do Córrego Capão Comprido no Distrito Federal.

xviii, 106p., 210 x 297 mm (ENC/FT/UnB, Mestre, Tecnologia Ambiental e Recursos Hídricos, 2005). Dissertação de Mestrado – Universidade de Brasília. Faculdade de Tecnologia.

Departamento de Engenharia Civil e Ambiental.

1. Imagens do SPOT-5

2. Imagens do QuickBird-2

3. Medidas de texturas

4. Classificação Textural

I. ENC/FT/UnB

II. Título (série)

REFERÊNCIA BIBLIOGRÁFICA

FERNANDES, S. C. (2005). *Avaliação de Imagens de Satélite de Alta e Muito Alta Resolução Espacial para a Discriminação de Classes de Uso e Ocupação do Solo: Aplicação ao caso da sub-bacia do Córrego Capão Comprido no Distrito Federal*. Dissertação de Mestrado em Tecnologia Ambiental e Recursos Hídricos, Publicação PTARH.DM-079/05, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 106p.

CESSÃO DE DIREITOS

AUTOR: Simoneli Cardoso Fernandes.

TÍTULO: Avaliação de Imagens de Satélite de Alta e Muito Alta Resolução Espacial para a Discriminação de Classes de Uso e Ocupação do Solo: Aplicação ao caso da sub-bacia do Córrego Capão Comprido no Distrito Federal.

GRAU: Mestre

ANO: 2005

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa dissertação de mestrado pode ser reproduzida sem autorização por escrito do autor.

Simoneli Cardoso Fernandes
simonele@gmail.com

Ao meu pai, Simonete,
exemplo de persistência
e responsabilidade.

A minha mãe, Roseli,
sinônimo de força e amor.

As minhas irmãs, Rosineli e Siseli,
fontes de aconchego e confiança.

A minha sobrinha, Anne Gabrielle,
significado de alegria.

DEDICO.

AGRADECIMENTOS

Este é um momento singular. Conseguir expressar os meus agradecimentos a todos aqueles que me acompanharam durante o curso do mestrado é uma tarefa difícil. Por isso, desde já, peço desculpas aos que não foram citados.

Agradeço a minha família que, mesmo estando distante, em momento algum me deixou desamparada. Pai, muito obrigada pelos ensinamentos e educação a mim proporcionados ao longo da vida...muito obrigada, mãe, por sua doação incondicional em todos esses anos de minha existência, pelas palavras de carinho e conforto a cada telefonema.

Minhas irmãs, vocês são maravilhosas, obrigada pelo constante incentivo e preocupação com o meu bem-estar. E não podia deixar de agradecer a minha sobrinha Anne, que, apesar de tão pequenina, a cada ida para casa nas férias e em cada ligação me surpreendia com o seu jeito sapeca e meigo.

Ao professor Nabil, que mesmo distante por um período, orientou-me com boa vontade, paciência, questionamentos e pronta ajuda durante a fase de dissertação. Obrigada pela confiança a mim dispensada.

Ao professor Nestor, que sempre esteve disposto a esclarecer as dúvidas e a contribuir com o andamento da pesquisa.

Aos professores Oscar, Sérgio Koide, Cristina e Marco Antônio, pelos conhecimentos transmitidos ao longo desse tempo.

Às amigas Simone, Jailma e Cristiane, grupo formado na época da graduação e fielmente consolidado no mestrado, período em que, longe de nossas famílias, compartilhamos todos os momentos de angústias, alegrias e tantas noites em claro.

Ao amigo Carlos Henrique, pelo estímulo, sugestões, conselhos e descontrações, acalmando as minhas inquietações ao longo do mestrado.

Aos demais amigos da turma de 2003, Daidi, Itonaga, Thales, Camila, Fuad, Daniela Pablo, Viviane, Juliana e Gustavo, pela troca de idéias, divertimentos e amizade construída ao longo desse período.

Às amigas feitas no programa de pós-graduação: Socorro, Fernan, Selma, Andréa Barnez, Vanusa, Luciana e Rafael. Em especial à Cláudia, Renata, Ana Elisa pela companhia e divertidos momentos compartilhados nesta etapa final.

Aos amigos distantes, em especial à Aretuza, Alisson, Abner, Júnior e Dinélica, pelo bom-humor, carinho e vários encontros na estrada virtual.

Ao cunhado Marcelo pelo incentivo e amizade.

Aos meus avós, tios e primos, que torceram por mim durante este período.

Aos técnicos do projeto CT-HIDRO, Marcos Pufal e Marco Vinícius, pelo auxílio técnico na manipulação dos equipamentos, atenção e presteza, bem como, aos colaboradores, João, Francisco e Júnior, pela ajuda nos trabalhos de campo.

Ao programa de pós-graduação em Tecnologia Ambiental e Recursos Hídricos que me proporcionou a infra-estrutura necessária para a realização deste trabalho.

Ao Conselho Nacional de Pesquisa e Tecnologia – CNPq, pela bolsa de mestrado.

Ao Sr. Joel, Sra. Glória, Sr. Roberto e Sra. Lurdes, pela acolhida ao chegar a Brasília.

Ao professor Álvaro Crosta, examinador externo da banca examinadora, pelas pertinentes sugestões.

A Deus, por tudo.

RESUMO

AVALIAÇÃO DE IMAGENS DE SATÉLITE DE ALTA E MUITO ALTA RESOLUÇÃO ESPACIAL PARA A DISCRIMINAÇÃO DE CLASSES DE USO E OCUPAÇÃO DO SOLO: APLICAÇÃO AO CASO DA SUB-BACIA DO CÓRREGO CAPÃO COMPRIDO NO DISTRITO FEDERAL

Autor: Simoneli Cardoso Fernandes

Orientador: Nabil Joseph Eid

Programa de Pós-Graduação em Tecnologia Ambiental e Recursos Hídricos

Brasília, Julho de 2005

As imagens de satélites de muito alta resolução espacial são produtos apresentados como promissores devido ao seu potencial de fornecer maior detalhamento da superfície terrestre.

Motivado por esse avanço no melhoramento da resolução espacial das imagens de satélite, efetuou-se um estudo com imagens dos satélites SPOT-5 e QuickBird-2, com o intuito de promover uma avaliação sobre o uso potencial desses produtos no que se refere ao ganho de informações no mapeamento do uso e ocupação do solo.

A pesquisa foi realizada na sub-bacia córrego Capão Comprido localizada na parte ocidental do Distrito Federal.

Para a geração dos mapas temáticos utilizou-se um classificador textural, que se baseia nas informações espectral e espacial, implementado no software SPRING, versão 4.1. A metodologia utilizada compreendeu os trabalhos de campo para reconhecimento da área e o processamento digital das imagens englobando as técnicas de realce para a interpretação visual, segmentação para a coleta das amostras de treinamento e seleção das medidas de textura para a finalização da classificação.

Os resultados da pesquisa mostraram que, pela interpretação visual, nas imagens pancromáticas do SPOT-5, houve dificuldade na diferenciação das coberturas vegetais dada a baixa resolução espectral. Quanto às imagens multiespectrais, no caso do QuickBird-2 obteve-se alto nível de detalhamento para a extração de informações da cena; no caso da imagem do SPOT-5 não foi possível fazer a diferenciação entre algumas coberturas vegetais. Outras conclusões relevantes foram: o desempenho médio do classificador, que é baseado nas amostras de treinamento, foi maior nas imagens multiespectrais; em todas as imagens, uma das possíveis causas da classificação errônea em algumas áreas, é atribuída ao desempenho limitado do algoritmo de segmentação utilizado.

ABSTRACT

EVALUATION OF HIGH AND VERY HIGH SPATIAL RESOLUTION SATELLITE IMAGES FOR LAND COVER AND LAND USE DISCRIMINATION IN THE CÓRREGO CAPÃO COMPRIDO SUB-BASIN

Author: Simoneli Cardoso Fernandes

Adviser: Nabil Joseph Eid

Programa de Pós-Graduação em Tecnologia Ambiental e Recursos Hídricos

Brasília, July, 2005

Very high spatial resolution satellite images are presented as promising products due to their potential of supplying greater detail of the earth surface. In this study, SPOT-5 and QuickBird-2 images were acquired with the intention to promote a study on the potential use of these products in terms of gain of information for land cover and land use mapping.

The study area, Córrego Capão Comprido sub-basin, is located in the western part of Distrito Federal.

For the thematic map generation, it was used a texture classifier implemented in the software SPRING, version 4.1. This classifier extracts spectral and spatial information.

The methodology included fieldwork for the recognition of the area and digital image processing including: enhancement techniques for the visual interpretation, segmentation technique for the collection of samples for the training stage and selection of the texture measures for the finalization of the classification.

The results showed that, for the visual interpretation, in SPOT-5 panchromatic images there was difficulty in differentiating land cover due to the low spectral quality. With relation to the multispectral images, the QuickBird-2 image provided high level of detail for the extraction of information from the scene; for the SPOT-5 image it was not possible to differentiate some types of vegetation covers. Other relevant conclusions were that the classification accuracy calculated from the confusion matrix was high for multispectral images. In all the images, one possible cause of the erroneous classification in some areas is attributed to the limited performance of the segmentation algorithm.

SUMÁRIO

1 - INTRODUÇÃO.....	1
2 - OBJETIVOS.....	5
3 - FUNDAMENTAÇÃO TEÓRICA.....	6
3.1 - IMAGENS ORBITAIS.....	6
3.1.1 - Satélite SPOT.....	7
3.1.2 - Satélite QuickBird.....	9
3.2 - PROCESSAMENTO DE IMAGENS DIGITAIS.....	10
3.2.1 - Segmentação de imagens digitais.....	11
3.2.2 - Classificação de imagens digitais.....	12
3.2.3- Exatidão da classificação.....	15
3.3 - ANÁLISE DE TEXTURA DAS IMAGENS.....	17
3.3.1- Matriz de co-ocorrência dos níveis de cinza.....	18
3.3.2- Medidas de textura de Haralick.....	21
4 - REVISÃO BIBLIOGRÁFICA.....	26
4.1 - Aplicação do sensoriamento remoto na agricultura irrigada.....	26
4.2 - Utilização de atributos texturais na classificação de imagens.....	28
5 - MATERIAIS E MÉTODOS.....	32
5.1 - ÁREA DE ESTUDO.....	32
5.2 - MATERIAIS.....	34
5.2.1 - Seleção das imagens.....	34
5.2.2 - Software.....	34
5.2.3 - Cartas planialtimétricas.....	35
5.2.4 - Sistema de posicionamento global.....	36
5.3 - METODOLOGIA.....	36
5.3.1 - Trabalho de campo.....	36
5.3.2 - Entrada dos dados.....	37
5.3.3 - Definição das classes de uso do solo.....	39
5.3.4 - Manipulação das imagens.....	40
5.3.4.1 - Interpretação das imagens.....	41
5.3.4.2 - Segmentação das imagens.....	43
5.3.4.3 - Classificador ClaTex.....	46

5.3.4.4 - Classificação das imagens multiespectrais.....	48
5.3.4.5 - Classificação das imagens pancromáticas.....	51
5.3.4.6 - Quantificação dos erros relativos na medição de áreas das classes temáticas.....	52
5.3.4.7 - Avaliação detalhada da classificação em uma área amostral.....	52
6 - RESULTADOS E DISCUSSÃO.....	55
6.1 - SEGMENTAÇÃO DAS IMAGENS.....	55
6.1.1 - Imagens do SPOT-5.....	55
6.1.2 - Imagens do QuickBird-2.....	58
6.1.3 - Comparação entre as segmentações das imagens.....	60
6.2 - CLASSIFICAÇÃO DAS IMAGENS.....	63
6.2.1 - Imagens multiespectrais.....	64
6.2.2 - Imagens pancromáticas.....	65
6.2.3 - Análise quantitativa nas classificações das imagens multiespectrais.....	67
6.2.4 - Análise da influência da resolução espacial.....	73
6.2.5 - Análise entre os mapas temáticos gerados e a verdade terrestre.....	74
6.2.5.1 - Imagem multiespectral do QuickBird-2 com resolução espacial de 2,8m.....	75
6.2.5.2 - Imagem multiespectral do SPOT-5 com resolução espacial de 10m.....	77
6.2.5.3 - Imagem pancromática do SPOT-5 com resolução espacial de 2,5m.....	79
6.2.5.4 - Imagem pancromática do SPOT-5 com resolução espacial de 5 m obtida pela reamostragem da imagem pan 2,5 m.....	80
6.2.5.5 - Imagem pancromática do SPOT-5 com resolução espacial de 10 m obtida pela reamostragem da imagem pan 2,5 m.....	82
6.2.6 - Comparação entre as classificações obtidas pelos diferentes produtos para uma área amostral.....	83
7- CONCLUSÕES E RECOMENDAÇÕES.....	90
REFERÊNCIAS BIBLIOGRÁFICAS.....	93
APÊNDICES.....	99

A-	FORMULAÇÃO MATEMÁTICA DE MEDIDAS DE DISTÂNCIA UTILIZADAS COMO REGRA DE DECISÃO.....	100
B-	FOTOS REFERENTES À CARACTERIZAÇÃO DA SUB-BACIA DO CAPÃO COMPRIDO.....	101
C-	DESEMPENHOS MÉDIOS OBTIDOS PARA A CLASSIFICAÇÃO DA IMAGEM MULTIESPECTRAL DO SPOT-5, UTILIZANDO-SE PARA CADA CAMADA DE TEXTURA AS MEDIDAS DE TEXTURAS INDIVIDUALMENTE.....	102
D-	MEDIDAS DE TEXTURA SELECIONADAS PELO FATOR DISCRIMINANTE ENTRE DUAS CLASSES.....	103

LISTA DE TABELAS

Tabela 3.1 - Características das resoluções espacial e espectral dos satélites SPOT-5.....	8
Tabela 3.2 - Características das resoluções espacial e espectral do satélite.....	10
Tabela 5.1 - Valores da variância das bandas espectrais correspondentes às imagens multiespectrais do SPOT-5 e QuickBird -2.....	41
Tabela 5.2 - Matrizes de coeficiente de correlação para as imagens multiespectrais do SPOT-5 e do QuickBird-2.....	41
Tabela 5.3 - Imagens originais e reamostradas dos satélites SPOT-5 e QuickBird -2.....	45
Tabela 6.1 - Matriz de classificação referente à imagem multiespectral do SPOT-5.....	67
Tabela 6.2 - Matriz de classificação a partir da imagem multiespectral do QuickBird-2.....	70
Tabela 6.3 - Áreas dos temas mapeados pela interpretação visual e pelo classificador ClaTex para a imagem multiespectral do QuickBird-2 e o erro relativo das áreas das classes temáticas geradas pelo classificador.....	75
Tabela 6.4 - Áreas dos temas mapeados pela interpretação visual e pelo classificador ClaTex para a imagem multiespectral do SPOT-5 e o erro relativo das áreas das classes temáticas geradas pelo classificador.....	77
Tabela 6.5 - Áreas dos temas mapeados pela interpretação visual e pelo classificador ClaTex para a imagem pancromática de 2,5 m do SPOT-5 e o erro relativo das áreas das classes temáticas geradas pelo classificador.....	79
Tabela 6.6 - Áreas dos temas mapeados pela interpretação visual e pelo classificador ClaTex para a imagem pancromática do SPOT-5 de 5 m reamostrada pela pan 2,5 m e o erro relativo das áreas das classes temáticas geradas pelo classificador.....	81

Tabela 6.7 - Áreas dos temas mapeados pela interpretação visual e pelo classificador ClaTex para a imagem pancromática do SPOT-5 de 5 m reamostrada pela pan 2,5 m e o erro relativo das áreas das classes temáticas geradas pelo classificador.....	83
Tabela 6.8 - Matriz de confusão a partir da imagem pancromática de 2,5 m do SPOT-5 (valores em %).....	86
Tabela 6.9 - Medidas das áreas em hectares das classes temáticas para a área amostral.....	88
Tabela C.1 - Desempenhos médios obtidos na classificação da imagem multiespectral do SPOT-5 para cada medida de textura.....	102
Tabela D.1 - Medidas selecionadas para a imagem multiespectral do SPOT-5.....	103
Tabela D.2 - Medidas selecionadas para a imagem multiespectral do QuickBird-2....	104
Tabela D.3 - Medidas selecionadas para a imagem pancromática do SPOT-5 com 2,5 m de resolução espacial.....	105
Tabela D.4 - Medidas selecionadas para a imagem pancromática do SPOT-5 com 5 m de resolução espacial.....	106

LISTA DE FIGURAS

Figura 3.1 -	Construção das matrizes de co-ocorrência de níveis de cinza.....	20
Figura 5.1 -	Representação da localização da sub-bacia do córrego Capão Comprido.....	32
Figura 5.2 -	Caracterização da sub-bacia do córrego Capão Comprido.....	34
Figura 5.3 -	Imagem fundida do QuickBird-2.....	42
Figura 5.4 -	Imagem multiespectral do SPOT-5, composição colorida realçada: R(banda2)G(banda3)B(banda1).....	48
Figura 5.5 -	Imagem multiespectral do QUICKBIRD-2, composição colorida realçada: R(banda3)G(banda4)B(banda2).....	50
Figura 6.1 -	Imagem rotulada a partir das bandas 1, 2 e 3 com os limiares 10 para similaridade e 20 para área.....	56
Figura 6.2 -	Imagem rotulada a partir da banda pancromática de 5 m com os limiares 6 para similaridade e 70 para área.....	56
Figura 6.3 -	Imagem rotulada a partir da banda pancromática de 2,5 m com os limiares 8 para similaridade e 140 para área.....	57
Figura 6.4 -	Imagem rotulada a partir da banda pancromática de 10 m obtida pela reamostragem da pan 5 m com os limiares 6 para similaridade e 20 para área.....	57
Figura 6.5 -	Imagem rotulada a partir da banda pancromática de 5 m obtida pela reamostragem da pan 2,5 m com os limiares 8 para similaridade e 70 para área.....	57
Figura 6.6 -	Imagem rotulada a partir da banda pancromática de 10 m obtida pela reamostragem da pan 2,5 m com os limiares 8 para similaridade e 20 para área.....	58
Figura 6.7 -	Imagem rotulada a partir das bandas 1, 2 e 3 com os limiares 7 para similaridade e 100 para área.....	59
Figura 6.8 -	Imagem rotulada a partir da banda pancromática de 0,70 m com os limiares 4 para similaridade e 1600 para área.....	60

Figura 6.9 -	Segmentação das imagens: a) pan 2,5 m, limiares (8/140); b) pan 5 m (2,5p5), limiares (8/70) e c) pan 10 m (2,5p10), limiares (8/20).....	61
Figura 6.10 -	Imagens rotuladas: a) multiespectral (10/20), b) pan 10 m reamostrada pela pan 5 m (6/20) e c)pan 10m reamostrada pela pan 2,5 m (8/20).....	62
Figura 6.11 -	a) Multiespectral (29/04/03), limiares 10/20 e b) pancromática (20/06/03), limiares 6/70.....	62
Figura 6.12 -	Amostras da imagem multiespectral do SPOT-5 (a1 a a5) e respectivas amostras do mapa temático (b1 a b5).....	69
Figura 6.13 -	Amostras da imagem multiespectral do QuickBird-2 (a1 a a5) e respectivas amostras do mapa temático (b1 a b5).....	71
Figura 6.14 -	Gráficos gerados a partir das matrizes de confusão.....	73
Figura 6.15 -	Classificação da imagem multiespectral do QuickBird-2 com 2,8 m de resolução espacial.....	76
Figura 6.16 -	Classificação da imagem multiespectral do SPOT-5 com 10 m de resolução espacial.....	78
Figura 6.17 -	Classificação da imagem pancromática do SPOT-5 com 2,5 m de resolução espacial.....	80
Figura 6.18 -	Classificação da imagem pancromática do SPOT-5 com resolução espacial de 5 m obtida pela reamostragem da imagem pan 2,5 m.....	82
Figura 6.19 -	Classificação da imagem pancromática do SPOT-5 com resolução espacial de 10 m obtida pela reamostragem da imagem pan 2,5 m.....	82
Figura 6.20 -	Composição colorida 2(B)3(R)4(G) do QuickBird-2 fundida, 0,70 m de resolução espacial.....	84
Figura 6.21 -	Imagem multiespectral do SPOT-5 com resolução espacial 10 m.....	85
Figura 6.22 -	Imagem pancromática do SPOT-5 com resolução espacial de 5 m.....	85
Figura 6.23 -	Imagem pancromática do SPOT-5 com resolução espacial de 2,5 m.....	86
Figura 6.24 -	Imagem multiespectral doQuickBird-2 com resolução espacial de 2,8 m.....	87
Figura B.1 -	Fotografias de uso e coberturas vegetais na área em estudo.....	101

LISTA DE SÍMBOLOS, NOMENCLATURA E ABREVIACÕES

θ	Ângulo
σ	Desvio padrão
μ	Média
CASI.....	Compact Airborne Spectrographic Imager
CBERS.....	China Brazil Earth Resources Satellite
CCD.....	Charge Coupled Device
CHI.....	Qui-quadrado
CNES.....	Centro Nacional de Estudos Espaciais
CODEPLAN.....	Companhia de Desenvolvimento do Planalto Central
CON.....	Contraste
COND.....	Contraste vetor diferença
COR.....	Correlação
d.....	Distância
DIS.....	Disssimilaridade
DN.....	Digital Number
EMATER/DF.....	Empresa de Assistência Técnica e Extensão Rural do Distrito Federal
ENE.....	Energia
ENED.....	Energia vetor diferença
ENES.....	Energia vetor soma
ENT.....	Entropia
ENTD.....	Entropia vetor diferença
ENTS.....	Entropia vetor soma
ESRI.....	Environmental Systems Research Institute
ETM.....	Enhanced Thematic Mapper
GLCM.....	Grey Level Co-occurrence Matrix
GPS.....	Global Position System
h.....	Hora
HOM.....	Homogeneidade
HRG.....	Haute Résolution Géométrique
HRS.....	Haute Résolution Steréoscopique
HRV.....	Haute Résolution Visible

HRVIR.....	Haute Résolution Visible et Infra Rouge
i.....	Nível de cinza i
IHS.....	Intensity Hue Saturation
INPE.....	Instituto Nacional de Pesquisas Espaciais
IVDN.....	Índice de Vegetação por Diferença Normalizada
j.....	Nível de cinza j
k.....	Variável referente à soma dos níveis de cinza i e j
km.....	Quilômetro
l.....	Variável referente à diferença dos níveis de cinza i e j
L_x	Domínio espacial horizontal
L_y	Domínio espacial vertical
m.....	Metro
MAP.....	Maximum a Posteriori
MAXVER.....	Máxima Verossimilhança
MD.....	Média vetor diferença
MDT.....	Modelo Digital de Elevação
min.....	Minuto
MRF.....	Markov Randon Fields
MS.....	Média vetor soma
N_g	Número de diferentes níveis de cinza quantizados na imagem
N_x	Número de pixels na direção horizontal
N_y	Número de pixels na direção vertical
nm.....	Nanômetro
NOAA.....	National Oceanic and Atmospheric Administration
$P(i,j)$	Elemento da matriz não normalizada de co-ocorrência de níveis de cinza
$p(i,j)$	Elemento da matriz normalizada de co-ocorrência de níveis de cinza
PROM.....	Cluster prominence
$P^D(l)$	Elemento do vetor diferença de níveis de cinza
$P^S(k)$	Elemento do vetor soma de níveis de cinza
R.....	Constante de normalização
REM.....	Radiação Eletromagnética
RGB.....	Red Green Blue
SAD.....	South American Datum
SHADE.....	Cluster shade

SIG.....	Sistemas de Informações Geográficas
SPOT.....	Satellite Pour l’Observation de la Terre
SPRING.....	Sistema de Processamento de Informações Georreferenciadas
SR.....	Sensoriamento Remoto
TM.....	Thematic Mapper
UTM.....	Universal Transversa de Mercator
VD.....	Variância vetor diferença
VS.....	Variância vetor soma
w.....	Oeste
WGS.....	World Geodetic System

1 – INTRODUÇÃO

A preocupação com as constantes transformações no meio físico tem sido verificada em escala mundial. O crescimento econômico sem políticas que possam ser efetivas para o gerenciamento dos recursos naturais e que acentuam o comprometimento do meio ambiente, é fato.

Um dos grandes desafios na gestão dos recursos naturais, em particular dos recursos hídricos, é adquirir e organizar informações que possam servir de subsídios à análise, monitoramento e planejamento ambiental.

Diante dessa problemática, faz-se necessário o desenvolvimento de estudos para um efetivo gerenciamento do uso desses recursos.

Nesse contexto, o planejamento torna-se essencial ao gerenciamento. Freitas (2000) comenta que a adoção da bacia hidrográfica como unidade de planejamento tem um aspecto positivo, pois a maioria dos problemas de causa-efeito aí gerados correlaciona-se ao uso dos recursos hídricos, cuja rede de drenagem se conforma a esses problemas.

Para que o planejamento e a administração dos recursos hídricos possam ser exercidos de forma racional e dinâmica, torna-se imperiosa a existência informações sistematizadas, e, sobretudo, de sistemas que articulem essas informações (Mendes e Cirilo, 2001).

A degradação ambiental, causada principalmente por atividades antrópicas, sem o uso racional dos recursos naturais, principalmente do solo, água e cobertura vegetal, tem causado sérios problemas qualitativos e quantitativos nos cursos d'água. O problema é acentuado nas regiões de vegetação de cerrado, cujas áreas têm sido bastante utilizadas para fins agrícolas, destacando-se o uso irracional de agrotóxicos, fertilizantes e da água.

De acordo com Mendes e Cirilo (2001), o impacto decorrente da alteração do uso do solo reflete em todos os componentes do ciclo hidrológico, como no escoamento superficial, na recarga dos aquíferos, na qualidade da água e no transporte de sedimentos.

Nesse enfoque, o conhecimento sobre o uso e ocupação das terras mostra-se essencial ao gerenciamento dos recursos hídricos.

É preciso dinamizar o processo de extração de dados sobre as bacias, gerando-se uma base de informações confiável e atualizada, principalmente no que se refere ao uso e ocupação das terras, configurando um componente relevante no processo de tomada de decisão.

Os avanços das geotecnologias têm permitido um melhor gerenciamento em diversas áreas como: administração, infra-estrutura, gestão ambiental, educação, dentre outras (Weske *et al.*, 1998).

Partindo desse princípio, a escolha do uso das geotecnologias, em particular do sensoriamento remoto, com o qual é possível a observação de grandes, médias e pequenas áreas, apresenta-se como uma alternativa para obtenção das informações que identifiquem e quantifiquem as características da superfície terrestre.

De acordo com a literatura, a união do sensoriamento remoto com o SIG tem sido reconhecida como uma ferramenta poderosa e eficaz na extração de informações sobre o meio físico, oferecendo suporte ao gerenciamento, ao planejamento e à tomada de decisões (Chen *et al.*, 2005; Treitz e Rogan, 2004; Prenzel, 2004).

Avaliações efetivas de planejamento e gerenciamento dos recursos ambientais em escalas locais e regionais dependem de um conhecimento sólido da distribuição e variabilidade do uso do solo dentro da área da bacia. As imagens de satélite são uma ferramenta excelente pela acurácia e custo-efetividade na avaliação multi-temporal das mudanças de uso da terra em escala regional (Ierodiaconou, 2005).

O sensoriamento remoto revela-se como uma poderosa ferramenta para aquisição de dados da superfície terrestre. A possibilidade de se adquirir uma grande quantidade de informações sobre o meio físico a partir das imagens de satélite não fornece apenas uma melhor compreensão quanto aos aspectos de utilização da terra, apresenta-se, também, como um papel vital na formulação de políticas e programas requeridos para o desenvolvimento do planejamento.

No caso dos recursos hídricos, a tecnologia do sensoriamento remoto continua sendo incorporada em um grande número de aplicações: medição de variáveis hidrológicas, como precipitação, temperatura da superfície terrestre, umidade do solo; criação de mapas temáticos a partir da classificação das imagens, etc. (Mendes e Cirilo, 2001).

A partir do mapa temático de uso e ocupação do solo é possível extrair um conjunto de parâmetros relacionados a cada classe, como área, interceptação vegetal, usos do solo, etc. Tais parâmetros podem ser incorporados a uma base de dados espaciais, que integradas a outras informações poderão ser utilizados em modelos hidrológicos a fim de simular o comportamento hidrológico da bacia.

De acordo com Florenzano (2002), as imagens de satélite proporcionam uma visão sinóptica (de conjunto) e multitemporal (de dinâmica) de extensas áreas da superfície terrestre. Esses produtos mostram-se como um recurso que contribui para a identificação dos diferentes usos do espaço terrestre e para o acompanhamento da transformação do ambiente.

Com o advento das imagens de satélites de muito alta resolução espacial, surge a possibilidade de se obter informações detalhadas, antes limitadas pelas imagens de média a alta resolução espacial.

Cabe ressaltar que os dados de sensoriamento remoto têm sido de utilidade crescente e contínua na geração e atualização de bancos de dados espacialmente referenciados. Nesse panorama, a inserção de imagens de muito alta resolução espacial solidifica seu uso para a extração de feições geográficas de imagens orbitais, que se insere como uma das fontes de dados relevantes para a constituição de Sistemas de Informações Geográficas (SIG's).

O surgimento de novos produtos em sensoriamento remoto, caracterizados pela muito alta resolução espacial, apresenta-se como promissora devido ao seu potencial de fornecer maior detalhamento da superfície terrestre, sendo assim um atrativo para a obtenção de dados de observação da terra.

A forma convencional de representar os dados obtidos a partir de imagens de satélites é resultante da classificação de imagens, que por sua vez produz o mapeamento temático.

Entretanto, os algoritmos mais usuais de classificação de imagens estão limitados ao reconhecimento dos padrões espectrais dos pixels, resultando frequentemente em uma classificação imprecisa (Atkinson, 2004; Raptis *et al.* 2003; Mendes e Cirilo, 2001). Essa restrição pode comprometer ainda mais a classificação quanto se trata de imagens de muito alta resolução espacial, dada a alta quantidade de pixels, provocando maior variabilidade espectral em uma mesma classe.

O interesse pelas imagens de muito alta resolução espacial para a produção de mapas temáticos refinados tem aumentado, e, em busca desse detalhamento, faz-se necessário realizar pesquisas com novos classificadores que incorporem outros atributos como: forma, tamanho, textura, área, etc.

Motivados por esse avanço na resolução espacial das imagens de satélite, foram adquiridas imagens dos satélites SPOT-5 e QuickBird-2, com o intuito de promover um estudo sobre o uso potencial desses produtos no que se refere ao ganho de informações no mapeamento do uso e ocupação do solo.

Selecionou-se para esse estudo a sub-bacia do córrego Capão Comprido, de característica tipicamente rural, localizada no Distrito Federal.

Para a geração dos mapas temáticos será utilizado um classificador textural, que se baseia nas informações espectral e espacial, implementado no aplicativo SPRING, versão 4.1.

2 – OBJETIVOS

Esta pesquisa tem como objetivo geral promover uma avaliação do uso de imagens de alta e muito alta resolução espacial para a identificação e mapeamento do uso e ocupação da terra na diversidade do espaço rural por meio da classificação textural, com vistas a efetuar uma avaliação posterior das vantagens comparativas de cada produto. Como caso de estudo e aplicação, foi utilizada a sub-bacia do córrego Capão Comprido, no Distrito Federal.

O objetivo geral pode ser dividido em alguns objetivos específicos:

- Avaliar a potencialidade do uso das medidas texturais de Haralick na discriminação das classes temáticas no processo de classificação;
- Analisar a capacidade de identificação dos alvos na interpretação visual das imagens multiespectrais e pancromáticas de diferentes resoluções espaciais;
- Analisar a influência da resolução espacial nos resultados de classificação das imagens;
- Comparar os resultados de classificação obtidos pelas imagens de satélites utilizadas.

3 – FUNDAMENTAÇÃO TEÓRICA

3.1 – IMAGENS ORBITAIS

De acordo com Florenzano (2002), as imagens obtidas pelos sensores remotos, como fonte de dados da superfície terrestre, são cada vez mais utilizadas para a elaboração de diferentes tipos de mapas.

O uso de imagens coletadas por satélites tem servido como valiosa ferramenta para extração de dados para estudos geológicos, ambientais, agrícolas, cartográficos, florestais, urbanos, etc.

As imagens digitais obtidas por satélite são formadas por um conjunto de células de tamanho fixo denominadas “pixel”, que correspondem a uma determinada área do terreno. Trata-se de uma representação matricial onde cada pixel é referenciado por coordenadas relativas à linha e à coluna da matriz (a partir da imagem), e está associado a um valor numérico (*digital number* – DN), que representa a energia refletida pela área correspondente a esse pixel, numa determinada faixa do espectro eletromagnético.

Nas décadas de 70 e 80, as aplicações do sensoriamento remoto estavam ligadas ao mapeamento ambiental em escalas médias e pequenas (1:50.000 a 1:1.000.000). Essa realidade começou a mudar com a entrada em órbita de novos satélites de maior resolução espacial, ampliando assim os campos de aplicações. Pode-se, desta forma, gerar mapas digitais em escalas maiores (1:10.000 a 1:25.000) e realizar análises mais detalhadas.

Existem vários sistemas em nível orbital utilizados para a aquisição de informações por sensoriamento remoto. Dentre os satélites usados no monitoramento ambiental e territorial, destacam-se os americanos da série Landsat e os franceses da série SPOT (*Satellite Pour l’Observation de la Terre*). Em relação aos novos satélites, caracterizados pela muito alta resolução espacial, pode-se citar o QuickBird e o Ikonos, ambos americanos. Um outro programa espacial que merece ser mencionado é o CBERS (*China Brazil Earth Resources Satellite*), resultado da cooperação entre o Brasil e a China, com características

semelhantes ao Landsat e SPOT. A escolha do sensor vai depender do tipo de estudo que se pretende realizar, levando-se em consideração o nível de detalhamento necessário.

A seguir serão descritas as características dos satélites SPOT e QuickBird, objetos de estudo dessa pesquisa.

3.1.1 – Satélite SPOT

O programa SPOT foi planejado e projetado como um sistema operacional e comercial, estabelecido pelo governo francês em 1978, com a participação da Suécia e Bélgica. O programa é gerenciado pelo CNES - Centro Nacional de Estudos Espaciais, que é o responsável pelo desenvolvimento e operação dos satélites. O sistema vem sendo operado desde de 1986 quando foi lançado o primeiro satélite, o SPOT-1. O SPOT-2 entrou em órbita em janeiro de 1990, seguido do SPOT-3 em setembro de 1993, SPOT-4 em março de 1998 e SPOT-5 em Maio de 2002 (Spot Image, 2004).

A órbita dos satélites SPOT é circular heliossíncrona. A altitude dos satélites SPOT é de 830 km, a inclinação da órbita em relação à linha do Equador é de 98,7° e o seu horário aproximado de passagem pelo Equador (horário local) é às 10h39min, no sentido descendente, com duração de 101,4min. Na visada nadir (vertical), a cada 26 dias os sensores coletam dados de uma mesma área. O SPOT apresenta dois sensores idênticos, podendo ser utilizados independentemente, tanto na geometria de visada como no modo espectral. Cada instrumento tem uma faixa de varredura de 60 km, com observação vertical. Quando os dois sensores operam em faixas adjacentes, a área imageada é de 117 km de largura. Na Tabela 3.1 podem ser observadas as características referentes aos instrumentos sensores dos satélites SPOT (Spot Image, 2004).

Tabela 3.1 - Características das resoluções espacial e espectral dos satélites SPOT (Spot Image, 2004).

Satélites	Sensores	Espectro eletromagnético	Tamanho do pixel	Bandas espectrais
SPOT-5	2HRGs (Haute Résolution Géométrique)	Pancromática	2.5 m ou 5 m	480 – 710 nm
		B1: verde	10 m	500 – 590 nm
		B2: vermelho	10 m	610 – 680 nm
		B3: infravermelho próximo	10 m	780 – 890 nm
		B4: infravermelho médio	10 m	1580 – 1750 nm
	Vegetation 1	B0: azul	1 km	430 – 470 nm
		B2: vermelho	1 km	610 – 680 nm
		B3: infravermelho próximo	1 km	780 – 890 nm
		B4: infravermelho médio	1 km	1580 – 1750 nm
	HRS (Haute Résolution Steréoscopique)	Pancromática	10 m	490 – 690 nm
SPOT-4	2HRVIRs (Haute Résolution Visible et Infra Rouge)	Monoespectral	10 m	610 – 680 nm
		B1: verde	20 m	500 – 590 nm
		B2: vermelho	20 m	610 – 680 nm
		B3: infravermelho próximo	20 m	780 – 890 nm
		B4: infravermelho médio	20 m	1580 – 1750 nm
	Vegetation 2	B0: azul	1 km	430 – 470 nm
		B2: vermelho	1 km	610 – 680 nm
		B3: infravermelho próximo	1 km	780 – 890 nm
		B4: infravermelho médio	1 km	1580 – 1750 nm
SPOT-1 SPOT-2 SPOT-3	2HRVs (Haute Résolution Visible)	Pancromática	10 m	500 – 730 nm
		B1: verde	20 m	500 – 590 nm
		B2: vermelho	20 m	610 – 680 nm
		B3: infravermelho próximo	20 m	780 – 890 nm

Cabe comentar que os sensores *Vegetation 1* e o *Vegetation 2*, que operam no SPOT-4 e SPOT-5, respectivamente, cobrem uma área de 2.250 km de largura, podendo-se obter a imagem de uma mesma área a cada 24 horas.

Com relação ao SPOT-5, esse satélite também leva a bordo dois sensores HRS (*Haute Résolution Stéréoscopique*), fornecendo uma cobertura estereoscópica de 120 x 600 km, adquirida pelos dois telescópios que formam o conjunto, sendo um deles com visada dianteira e outro com visada traseira. Os dados em esteresocopia, uma vez processados, resultarão em modelos numéricos de terreno de 10 m de precisão altimétrica. Possuem resolução temporal de 26 dias.

Quanto à quantização dos níveis de cinza, as imagens do SPOT possuem 8 bits, exceto os sensores *Vegetation 1* e *Vegetation 2* que possuem 10 bits.

3.1.2 – Satélite QuickBird

Os satélites QuickBird são uma série de satélites de muito alta resolução espacial operados pela empresa *EarthWatch*. Em setembro de 2001, a *EarthWatch* mudou o nome para *DigitalGlobe*. O QuickBird-1 foi lançado em 20 de novembro de 2000, mas não alcançou a órbita. No dia 18 de outubro de 2001 o segundo satélite, o QuickBird-2 foi lançado em órbita. Ambos os satélites foram inicialmente planejados para terem 1 metro de resolução espacial. Em dezembro de 2000, a *EarthWatch* obteve licença da NOAA (*National Oceanic and Atmospheric Administration*) para operar um sistema com uma resolução espacial de 0,5m. Os planos do QuickBird-2 foram modificados para aumentar a resolução espacial originalmente projetado para 1 metro alterando para 0,61 metro (DigitalGlobe, 2004).

No que se refere às especificações técnicas do QuickBird, tem-se que a órbita desse satélite é circular heliossíncrona a uma altitude de 450 km. A inclinação da órbita é de 97,2° e o sentido da órbita é descendente com passagem no Equador (horário local) às 10h30min. O intervalo de revisita é de 1 a 3,5 dias dependendo da latitude. Cada imagem obtida cobre uma faixa de 16,5 km (DigitalGlobe, 2004).

O QuickBird-2 possui dois sensores do tipo *Charge Coupled Device* (CCD), que realizam varredura eletrônica em fileira linear (*pushbroom linear array*) flexíveis para visadas off-nadir até 30°, ao longo do terreno (*along-track*) imageado. Os sensores do tipo CCD *pushbroom* também são utilizados pelo SPOT, Ikonos e CBERS.

A *DigitalGlobe* adquire as imagens com 11 bits, podendo ser fornecidas em 8 bits ou 16 bits. A Tabela 3.2 apresenta as características referentes às resoluções espaciais e espectrais do QuickBird-2.

Tabela 3.2 - Características das resoluções espacial e espectral dos satélites QuickBird (DigitalGlobe, 2004).

Espectro eletromagnético	Tamanho do pixel	Bandas espectrais
Pancromática	0,70m	450 – 900 nm
B1: azul	2,8m	450 – 520 nm
B2: verde	2,8m	520 – 600 nm
B3: vermelho	2,8m	630 – 690 nm
B4: infravermelho próximo	2,8m	760 – 900 nm

3.2 – PROCESSAMENTO DE IMAGENS DIGITAIS

Segundo Fonseca (2000), o processamento de imagens digitais visa a identificar e a extrair informações da imagem, como também transformar a imagem (por exemplo, aumentar o contraste e realçar bordas) de tal modo que a informação seja mais facilmente discernível por um analista humano.

O mesmo autor divide as técnicas de processamento de imagens digitais em três etapas distintas: pré-processamento de imagens, realce de imagens e análise de imagens.

O pré-processamento permite a transformação de dados digitais brutos em dados corrigidos radiométrica e geometricamente.

A interpretação de imagens é, muitas vezes, dificultada pelas degradações inseridas nos processos de geração e visualização de imagens. As técnicas de realce têm a finalidade de melhorar a qualidade visual da imagem e enfatizar alguma característica de interesse para uma aplicação específica.

A análise de imagens está relacionada com a extração de informação de imagens. Inclui a segmentação de imagens e classificação de imagens.

A seguir será efetuada uma abordagem das técnicas de segmentação e classificação das imagens, sem detalhamento matemático, com o intuito de mostrar a funcionalidade desses métodos.

3.2.1 - Segmentação de imagens digitais

De acordo com Moreira (2001), a segmentação é um processo de particionamento do espaço de atributos espectrais em regiões homogêneas, ou seja, a localização de regiões na imagem que possuem pixels com características similares. A partir da segmentação de uma imagem pode-se iniciar a definição de padrões ou de classes a serem discretizadas.

Segundo Gonzáles e Woods (2002), os algoritmos de segmentação, geralmente, baseiam-se nas propriedades de valores de níveis de cinza: descontinuidade e similaridade.

A descontinuidade consiste em particionar a imagem por meio de mudanças bruscas nos níveis de cinza (detecção de pontos isolados, detecção de linhas e bordas na imagem). A similaridade consiste em agregar pixels com características similares em regiões.

No SPRING existem dois algoritmos de segmentação: crescimento por regiões e detecção de bacias.

O segmentador crescimento por regiões utiliza dois limiares: similaridade e de área. O limiar de similaridade está baseado na distância Euclidiana entre os valores médios dos níveis de cinza de cada região. Assim duas regiões são consideradas distintas se a distância entre suas médias for superior ao limite de similaridade escolhido. O limiar de área limita o tamanho mínimo (número de pixels) que uma região pode ter na imagem segmentada. As regiões que não obedecem ao critério mínimo da região são agrupadas à região mais freqüente ao seu redor (Câmara *et al.*, 1996).

O algoritmo de detecção de bacias calcula um limiar para a perseguição de bordas. Quando ele encontra um pixel com valor superior ao limiar estabelecido, tem início o processo de perseguição da borda. Observa-se a vizinhança para identificar o próximo pixel de maior valor de nível digital e segue-se nesta direção, até que se encontre outra borda ou a

fronteira da imagem. Neste processo gera-se uma imagem binária com os valores de 1 referentes às bordas e 0 para as regiões de não-bordas (Câmara *et al.*, 1996).

3.2.2 – Classificação de imagens digitais

A classificação digital, de acordo com Lillesand e Kiefer (1994), tem como objetivo categorizar, por meio de procedimentos computacionais, todos os pixels de uma determinada imagem, atribuindo a cada um deles um “rótulo” que os relaciona a um objeto do mundo real (vegetação, solo, etc). Assim, os valores numéricos associados a cada pixel, definidos pela reflectância dos materiais que compõem esse pixel, são identificados em termos de um tipo de cobertura da superfície terrestre imageada (água, tipo de solo, de vegetação, etc.), podendo ser chamadas de temas ou classes.

No que se refere aos tipos de classificadores, Câmara *et al.* (1996) comentam que estes podem ser divididos em: classificadores “pixel a pixel” e classificadores por regiões.

Os classificadores pixel a pixel utilizam apenas a informação espectral, isoladamente, de cada pixel para achar regiões homogêneas. Estes classificadores podem ser ainda separados em métodos estatísticos (que utilizam regras da teoria de probabilidade) e determinísticos (que não o fazem).

Os classificadores por regiões utilizam, além de informação espectral de cada pixel, a informação espacial que envolve a relação entre os pixels e seus vizinhos. Estes classificadores procuram simular o comportamento de um foto-intérprete, ao reconhecer áreas homogêneas de imagens, baseados nas propriedades espectrais e espaciais de imagens. A informação de borda é utilizada inicialmente para separar as regiões e as propriedades espaciais e espectrais que irão unir áreas com mesma textura.

As técnicas de classificação podem ser divididas em três grupos: classificação supervisionada, classificação não-supervisionada e classificação híbrida.

De acordo com Sabins Jr. (1987), na classificação supervisionada, o analista seleciona os locais de treinamento, que correspondem a áreas representativas para cada classe. Em um local de treinamento, as informações de cada pixel são usadas para definir o espaço de

decisão para essa classe. Depois que os conjuntos para cada local do treinamento são definidos, o computador classifica, então, todos os pixels remanescentes da cena. Os algoritmos de classificação supervisionados convencionais baseiam-se somente na informação espectral, os mais utilizados são: método da Distância Mínima, método do Paralelepípedo e método da Máxima Verossimilhança.

O mesmo autor define a classificação não-supervisionada como um método que executa uma análise de agrupamento onde são identificados no espaço de atributos os conjuntos de pixels com características espectrais similares. Ao contrário do método supervisionado, esse método não requer locais de treinamento especificados pelo analista. Os algoritmos de classificação não-supervisionados mais conhecidos são: o K-médias, o Isodata e o Isoseg.

Em relação à classificação híbrida, esta utiliza uma classificação não-supervisionada com base para a seleção de amostras de treinamento para realizar uma classificação supervisionada (Novo, 1992).

Com o surgimento de imagens de alta resolução espacial, desenvolvimentos de estudos e elaboração de novos classificadores que reconheçam não só padrões espectrais, mas que também considerem outros elementos como forma, tamanho, textura, relações de vizinhança, estão sendo cada vez mais requeridos.

Na literatura é possível encontrar diferentes metodologias que efetuam a extração de medidas de textura: matriz de co-ocorrência dos níveis de cinza, análise do semivariograma, filtros de Garbor, campo aleatório de Markov, transformada de Fourier, decomposição de “wavelet” (Ruiz *et al.* 2004).

No aplicativo SPRING, versão 4.1, software utilizado nesta pesquisa para o processamento das imagens, tem-se os seguintes classificadores:

- Classificadores pixel a pixel: método da Máxima Verossimilhança (MAXVER), MAXVER-ICM, Distância Euclidiana e K-médias.
- Classificadores por regiões: Isoseg, Battacharya, ClaTex.

Baseado em Lillesand e Kiefer (1994), Fonseca (2000) e INPE (2004), será comentado de forma sucinta o funcionamento dos algoritmos implementados no SPRING.

O classificador MAXVER é um algoritmo supervisionado, que assume que a dispersão dos pixels pertencentes a cada categoria (selecionados na fase de treinamento) ajusta-se a uma distribuição normal nas bandas espectrais. Funções de densidade de probabilidade geradas com base nos dados de média e variância/covariância das respostas espectrais das amostras de treinamento são utilizadas para estimar a probabilidade de um pixel pertencer a uma das classes. No critério de decisão pode-se utilizar o limiar de aceitação, de modo que os pixels não enquadrados dentro desse limiar não serão classificados.

O classificador MAXVER-ICM é um algoritmo supervisionado que considera a dependência espacial. Na primeira etapa a imagem é classificada pelo algoritmo MAXVER e em seguida é o classificador atribui classes a um determinado pixel, considerando a sua vizinhança iterativamente. Esse algoritmo também utiliza o limiar de aceitação.

O método da Distância Euclidiana, assim como os anteriormente citados, requer a fase de coleta das amostras. Um dado pixel será atribuído a uma classe a partir da análise de medida de similaridade da distância euclidiana, sendo agrupado a uma classe se o seu valor for menor do que o valor da média dessa classe. No SPRING, esse algoritmo não possui a ferramenta limiar de aceitação.

Dentre os classificadores pixel a pixel presentes no SPRING, o K-médias é o único não supervisionado. O analista apenas fornece o número de classes e o número de iterações a ser executado pelo algoritmo. Inicialmente, o algoritmo arbitrariamente agrupa os pixels em k classes, determinando as médias iniciais de cada grupo. Cada pixel é comparado a todas as médias, sendo associado ao cluster que proporcionou a menor distância euclidiana. No SPRING, o procedimento é finalizado ao atingir número de iterações fixado.

Quanto aos classificadores por regiões, estes requerem uma imagem segmentada para a classificação das regiões. Dentre os três classificadores por regiões implementados no Spring, apenas o classificador Iseseg é não supervisionado.

O classificador Iseseg efetua o agrupamento de dados por regiões. Esse procedimento é baseado nos atributos estatísticos de média e matriz de covariância referentes às regiões que estão sendo avaliadas. O cálculo da distância mínima entre regiões pertencentes a uma mesma classe é baseado no limiar de aceitação fixado pelo analista.

O classificador Battacharya utiliza a medida de distância Battacharya para calcular a distância média entre as distribuições de probabilidades de classes espectrais.

O classificador ClaTex reconhece os padrões texturais. Esse algoritmo efetua o agrupamento de regiões com base na medida de similaridade entre elas, que por sua vez é realizada a partir da distância de Mahalanobis. Para a extração da informação textural o classificador dispõe de um conjunto de medidas estatísticas que estão divididos em seis grupos:

- Medidas gerais: média, variância, desvio padrão, curtoses, assimetria e coeficiente de variação;
- Medidas em histograma: mediana, desvio médio absoluto, entropia e energia;
- Medidas logarítmicas: logaritmos da média, da variância, do desvio e da textura;
- Medidas de autocorrelação: medidas de autocorrelação espacial bidimensional;
- Medidas de Haralick: entropia, contraste, energia, homogeneidade, dissimilaridade, correlação, qui-quadrado, *cluster shade*, *cluster prominence*, e a média, variância, energia e entropia dos vetores soma e diferença, e o contraste do vetor diferença;
- Medidas Morfológicas.

No Apêndice A estão descritas matematicamente as medidas de distância de Mahalanobis, Battacharya, Euclidiana e Mínima, métodos utilizados como regra de decisão para a classificação da imagem.

3.2.3 – Exatidão da classificação

Para uma classificação ser confiável, deve-se efetuar a análise de acurácia da classificação. Em sensoriamento remoto o termo acurácia é tipicamente usado pra expressar o grau de exatidão de uma classificação (Lillesand e Kiefer, 1994).

Skimabukuro (1996) realizou uma extensa pesquisa bibliográfica a respeito da análise de exatidão da classificação das imagens. Os relatos apresentados a seguir são baseados nas informações obtidas por esse autor.

Conforme a sua pesquisa, os fatores que afetam a exatidão e a confiabilidade das informações obtidas pela classificação de dados de sensoriamento remoto podem ser

divididos em erro de classificação – decorrente da sobreposição espectral de duas ou mais classes definidas pelo analista – e erro de rotulação referente às situações onde há um conhecimento incompleto dos tipos de coberturas presentes na região por parte do analista.

Shimabukuro (1996) verificou que diversas causas para os erros têm sido abordadas em estudos realizados sobre a exatidão de classificação de imagens e mapas de cobertura vegetal, como: erros causados por pré-processamento; por técnicas interpretativas manuais e digitais; por sistemas imageadores; por técnicas de amostragem; por cálculo de exatidão e por comparação de resultados.

O mesmo autor atenta para a confiabilidade da exatidão da classificação. São apontadas falhas nos métodos de obtenção da exatidão elaborados a partir de amostras de áreas com poucas informações atualizadas da cobertura e/ou em áreas de difícil acesso, onde a verificação das amostras pode se tornar inviável. Expõe, ainda, que essa confiabilidade depende do número e tamanho das amostras adotadas. Ao se tratar de uma avaliação de exatidão baseada em amostras, o ideal é que se utilize um intervalo de confiança. Esse intervalo de confiança é o segmento dentro do qual há um nível de confiança pré-determinando de que o valor da estimativa estará correto.

Apesar de haver várias técnicas para calcular o número de amostras e o tamanho ideal das amostras, não há um método consensual.

Com relação aos diferentes métodos utilizados para representar o grau de exatidão, o mais difundido é o da matriz de erro, também conhecida como matriz de confusão ou tabela de contingência. A matriz de confusão é calculada a partir das áreas de treinamento. Trata-se de uma tabulação cruzada entre os pixels que representam a verdade de campo ou dados de referência e os pixels classificados pelo algoritmo. Os elementos da diagonal principal representam os pixels corretamente classificados, enquanto que os fora da diagonal principal referem-se aos pixels confundidos com outras classes (Foody, 2002).

No trabalho de Shimabukuro (1996), cita-se que a partir da matriz de erros pode-se determinar a exatidão da classificação por meio de técnicas analíticas e de técnicas descritivas.

Segundo Shimabukuro (1996), a técnica descritiva “exatidão global” é a mais usual. A sua obtenção é a partir da divisão da soma do número de pixels nas amostras classificadas corretamente (diagonal principal) pelo número total de pixels das amostras de treinamento.

Em se tratando das técnicas de analíticas são citadas: intervalo de confiança, teste de hipótese para decidir a aceitabilidade da exatidão de um mapa ou classe; análise de variância e análise multivariada discreta. Nesse enfoque, um método bastante conhecido é a análise Kappa.

A análise Kappa é um método multivariado discreto utilizado para calcular a medida de concordância global. Essa análise é baseada na diferença entre a concordância real de classificação e os dados de referência. São considerados os dados da diagonal principal e a ocorrência casual entre as classes.

Para a obtenção de informações detalhadas a respeito da avaliação de exatidão recomenda-se leitura do trabalho fonte – Shimabukuro, 1996 – utilizado na explanação dessa subseção.

É válido comentar que no aplicativo SPRING a análise de exatidão é realizada somente pela matriz de confusão, que é calculada para as amostras de treinamento. A técnica disponível para a obtenção do desempenho médio é a exatidão global. Em alguns algoritmos é possível adotar um intervalo de confiança. No caso do classificador textural, não há essa última opção.

3.3- ANÁLISE DE TEXTURA DAS IMAGENS

Segundo vários autores (Baraldi e Parmiggiani,1995; Nascimento *et al.*, 2003; Morales *et al.*,2003), a textura é uma das características mais importantes para classificar e reconhecer objetos e cenas, e pode ser caracterizada por variações locais em valores de pixels que se repetem de maneira regular ou aleatória ao longo do objeto ou imagens. Pode ser definida, ainda, como um efeito visual que é produzido pela distribuição espacial de variações de tonalidade.

De acordo com Ruiz *et al.* (2004), a análise de textura apresenta possibilidades interessantes para caracterizar a heterogeneidade estrutural das classes. Também comentam

que a textura oferece informações a respeito do contraste, uniformidade, rugosidade, regularidade, etc.

Utilizando-se um método estatístico para fazer a análise de textura, pode-se avaliar essa distribuição espacial da intensidade dos valores dos níveis de cinza nas diferentes áreas de uma imagem.

A ordem específica da textura é extraída baseada na dimensão do número de vetores de níveis de cinza sob investigação. Por exemplo, a textura de primeira ordem é calculada baseando-se apenas na frequência de um nível de cinza na vizinhança, enquanto que a textura de segunda ordem, baseia-se na frequência de um par de níveis de cinza, ou seja, além da distribuição espacial dos níveis de cinza na imagem este considera a relação espacial entre os pixels. (Wang *et al.*, 2004).

Haralick *et al.* (1973), propuseram uma importante técnica para a definição de características texturais, denominada matriz de co-ocorrência dos níveis de cinza.

Ruiz *et al.* (2002) e Greespan *et al.* (1994) ressaltam que, devido ao considerável número de quantidades de características texturais que podem ser extraídas das imagens e ao complexo processo automatizado para o reconhecimento de padrões de textura, os resultados obtidos utilizando atributos texturais devem ser considerados aplicáveis especificamente ao estudo em questão.

3.3.1 – Matriz de co-ocorrência dos níveis de cinza

A matriz de co-ocorrência é uma tabulação de quantas combinações diferentes de valores de intensidade dos pixels (níveis de cinza) ocorrem em uma imagem. A idéia principal dessa matriz é caracterizar texturas em uma imagem por meio de um conjunto de estatísticas para as ocorrências de cada nível de cinza em pixels diferentes ao longo de diferentes direções (Schwartz e Pedrini, 2003).

A co-ocorrência pode ser descrita por uma matriz de frequências relativas $P(i, j, d, \theta)$, bidimensional, na qual dois pixels separados por uma distância d , na orientação θ , aparecem em uma imagem, onde um deles tem nível de cinza “i” e outro “j”. Em outras

palavras, trata-se de uma representação da distribuição de probabilidade de ocorrência de um par de níveis de cinza i e j , medido a partir de uma distância “ d ” e de um ângulo “ θ ”.

A metodologia desenvolvida para o cálculo de matrizes de co-ocorrência de níveis de cinza considera que a imagem a ser analisada é retangular com N_x pixels na direção horizontal, N_y pixels na direção vertical e quantização espectral de N_g níveis de cinza. Tem-se que $L_x=\{1,2,\dots,N_x\}$ é o domínio espacial horizontal, $L_y=\{1,2,\dots,N_y\}$ é o domínio espacial vertical e $G=\{1,2,\dots,N_g\}$ o conjunto de N_g níveis de cinza quantizados. $L_y \times L_x$ refere-se ao conjunto de pixels da imagem ordenada pelas designações de suas linhas e colunas. A imagem “ I ” pode ser representada como uma função que atribui um nível de cinza no G para cada pixel. Assume-se que a informação textural da imagem “ I ” é especificada pela frequências relativas da matriz. (Haralick *et al.*, 1973).

De acordo com Haralick *et al.*(1973), as frequências não normalizadas P_{ij} da matriz de co-ocorrência na imagem “ I ” para distância d e ângulos quantizados por intervalos de 45° são definidos por:

$$P(i, j, d, 0^\circ) = \# \{((e, f), (q, r) \in (L_x \times L_y) \times (L_y \times L_x) : \quad \text{Equação (3.2)}$$

$$e - q = 0, |f - r| = d, I(e, f) = i, I(q, r) = j\}$$

$$P(i, j, d, 45^\circ) = \# \{((e, f), (q, r) \in (L_x \times L_y) \times (L_y \times L_x) : \quad \text{Equação (3.3)}$$

$$(e - q = d, f - r = -d) \text{ ou } (e - q = -d, f - r = d),$$

$$I(e, f) = i, I(q, r) = j\}$$

$$P(i, j, d, 90^\circ) = \# \{((e, f), (q, r) \in (L_x \times L_y) \times (L_y \times L_x) : \quad \text{Equação (3.4)}$$

$$|e - q| = d, f - r = 0, I(e, f) = i, I(q, r) = j\}$$

$$P(i, j, d, 135^\circ) = \# \{((e, f), (q, r) \in (L_x \times L_y) \times (L_y \times L_x) : \quad \text{Equação (3.5)}$$

$$(e - q = d, f - r = d) \text{ ou } (e - q = -d, f - r = -d),$$

$$I(e, f) = i, I(q, r) = j\}$$

onde:

$I(e, f)=i$, indica que o elemento pertencente a linha “ e ” e coluna “ f ” possui valor de nível de cinza “ i ”;

$\#((e,f),(q,r)) = \#(i,j)$, indica o número de ocorrência do par de níveis de cinza, um com $NC=i$ e outro com $NC=j$, separados por uma dada distância e direção considerada.

Essas quatro direções originam quatro matrizes de co-ocorrência distintas. Haralick *et al.* (1973) comentam que as matrizes $P(i, j, d, \theta)$ e $P(j, i, d, \theta)$ são simétricas. A distância métrica ρ (cálculo da distância entre dois pixels) implícita nas equações anteriores pode ser definida por:

$$\rho((e,f),(q,r)) = \max \{|e - q|, |f - r|\} \quad \text{Equação (3.6)}$$

Onde (e,f) e (q,r) são as coordenadas dois pixels analisados.

Cada elemento da matriz de co-ocorrência não normalizada corresponde à contagem dos pares de níveis de cinza i e j , com distância d e ângulo θ .

A Figura 3.1 ilustra a construção de uma matriz de co-ocorrência. A Figura 3.1 (a) mostra uma imagem 4x4 com quatro níveis de cinza. A Figura 3.1 (b) apresenta a montagem da matriz de co-ocorrência para uma imagem com variação de níveis de cinza entre os valores 0-3. A Figuras 3.1(c) – (d) exibem respectivamente as matrizes de co-ocorrência para uma distância $d=1$ e ângulos 0° , 45° , 90° e 135° .

0	0	1	1
0	0	1	1
0	2	2	2
2	2	3	3

(a)

# (0,0)	# (0,1)	# (0,2)	# (0,3)
# (1,0)	# (1,1)	# (1,2)	# (1,3)
# (2,0)	# (2,1)	# (2,2)	# (2,3)
# (3,0)	# (3,1)	# (3,2)	# (3,3)

(b)

$$\begin{bmatrix} 4 & 2 & 1 & 0 \\ 2 & 4 & 0 & 0 \\ 1 & 0 & 6 & 1 \\ 0 & 0 & 1 & 2 \end{bmatrix}$$

(c)

$$\begin{bmatrix} 4 & 1 & 0 & 0 \\ 1 & 2 & 2 & 0 \\ 0 & 2 & 4 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

(d)

$$\begin{bmatrix} 6 & 0 & 2 & 0 \\ 0 & 4 & 2 & 0 \\ 2 & 2 & 2 & 2 \\ 0 & 0 & 2 & 0 \end{bmatrix}$$

(e)

$$\begin{bmatrix} 2 & 1 & 3 & 0 \\ 1 & 2 & 1 & 0 \\ 3 & 1 & 0 & 2 \\ 0 & 0 & 2 & 0 \end{bmatrix}$$

(f)

Figura 3.1 - Construção da matriz de co-ocorrência (Haralick *et al.* 1973, modificado).

Considerando o exemplo numérico (Figura 3.1), Haralick *et al.* (1973) explicam de uma outra forma como é efetuada a contagem do número de ocorrência dos pares de níveis de cinza i e j , com uma distância d e ângulo θ .

Quando a relação do pixel de referência é com o pixel mais próximo na direção horizontal ($d=1, \theta=0^\circ$), haverá $2(N_x-1)$ pares de pixels em cada linha e N_y colunas, totalizando $2N_y(N_x-1)$ pares de pixels. Quando a relação é com o pixel da diagonal direita ($d=1, \theta=45^\circ$), haverá $2(N_x-1)$ para cada linha exceto para a primeira, que não existe, e N_y colunas. Isso estabelece um total de $2(N_y-1)(N_x-1)$ pares de pixels. Por simetria, haverá $2N_x(N_y-1)$ pares de pixels na direção vertical ($d=1, \theta=90^\circ$) e $2(N_x-1)(N_y-1)$ pares de pixels na direção diagonal esquerda ($d=1, \theta=135^\circ$).

A matriz de co-ocorrência é normalizada, dividindo cada elemento da matriz pelo valor da somatória de todos os seus elementos (R) denominada constante de normalização.

Então a frequência de co-ocorrência normalizada p_{ij} é igual a:

$$p(i, j)_{d,\theta} = \frac{P(i, j)_{d,\theta}}{R} \quad \text{Equação (3.7)}$$

A partir da matriz normalizada são extraídas as medidas de Haralick.

3.3.2 – Medidas de textura de Haralick

Haralick *et al.* (1973) propuseram uma metodologia de classificação de imagens utilizando medidas estatísticas de segunda ordem, baseadas no cálculo de matrizes de co-ocorrência de níveis de cinza, para medir características texturais.

Um grande número de características texturais tem sido proposto. Iniciando com Haralick *et al.* (1973) que descreveram 14 medidas estatísticas. Rennó *et al.* (1998) desenvolveram um sistema que utiliza dezoito medidas estatísticas: entropia, contraste, energia, homogeneidade, dissimilaridade, correlação, chi-quadrado, média do vetor soma, variância do vetor soma, entropia do vetor soma, energia do vetor soma, média do vetor diferença,

variância do vetor diferença, entropia do vetor diferença, energia do vetor diferença, contraste do vetor diferença, *cluster shade* e *cluster prominence*.

A partir da literatura (Baraldi e Parmiggiani, 1995; Soares *et al.*, 1997; Tuceryan e Jain, 1998; Hall-Beyer, 2000; Albregtsen, 2003; e Nascimento *et al.*, 2003) são descritas algumas medidas derivadas da matriz de co-ocorrência de níveis de cinza.

- Energia (segundo momento angular): este parâmetro mede a uniformidade da textura, isto é, as repetições de pares de pixels.

$$ENE_{d,0} = \sum_i \sum_j p(i, j)_{d,0}^2 \quad \text{Equação (3.8)}$$

- Contraste: está relacionada à frequência espacial da vizinhança. Altos valores de contraste são indicativos de altos valores de níveis de cinza fora da diagonal principal.

$$CON_{d,0} = \sum_i \sum_j (i - j)^2 p(i, j)_{d,0} \quad \text{Equação (3.9)}$$

- Entropia: mede o grau de dispersão de ocorrências de níveis de cinza em uma imagem. Quando a imagem não é texturalmente uniforme, a entropia é muito alta. Conceitualmente, a entropia e a energia estão inversamente correlacionadas.

$$ENT_{d,0} = - \sum_i \sum_j p(i, j)_{d,0} \log p(i, j)_{d,0} \quad \text{Equação (3.10)}$$

- Homogeneidade (momento da diferença inversa): mede a concentração das ocorrências de níveis de cinza na diagonal da matriz de co-ocorrência, resultando em grandes valores para níveis de cinza similares.

$$HOM_{d,0} = \sum_i \sum_j \frac{p(i, j)_{d,0}}{1 + (i - j)^2} \quad \text{Equação (3.11)}$$

- Dissimilaridade: similar ao contraste. Apresenta grandes valores para imagens compostas principalmente por níveis de cinza diferentes.

$$DIS_{d,0} = \sum_i \sum_j p(i, j)_{d,0} |i - j| \quad \text{Equação (3.12)}$$

- Correlação: mede a dependência linear dos tons de cinza na imagem. Valores de alta correlação implicam em uma relação linear entre níveis de cinza dos pares de pixels.

$$\text{COR}_{d,\theta} = \frac{\sum_i \sum_j (ij) p(i, j)_{d,\theta} - \mu_x \mu_y}{\sigma_x \sigma_y} \quad \text{Equação (3.13)}$$

- Qui-quadrado: pode ser entendida como a normalização da energia da área de interesse para uma dependência linear dos níveis de cinza na imagem. Essa medida é correlacionada à energia.

$$\text{CHI}_{d,\theta} = \frac{\sum_i \sum_j \frac{p(i, j)_{d,\theta}^2}{\sum_j p(i, j)_{d,\theta} \sum_i p(i, j)_{d,\theta}}}{\sum_i \sum_j p(i, j)_{d,\theta}} \quad \text{Equação (3.14)}$$

- Cluster shade:

$$\text{SHADE}_{d,\theta} = \sum_i \sum_j (i + j - \mu_x - \mu_y)^3 p(i, j)_{d,\theta} \quad \text{Equação (3.15)}$$

- Cluster prominence

$$\text{PROM}_{d,\theta} = \sum_i \sum_j (i + j - \mu_x - \mu_y)^4 p(i, j)_{d,\theta} \quad \text{Equação (3.16)}$$

Onde:

- μ_x, μ_y são médias e σ_x, σ_y são desvios padrão

$$\mu_x = \sum_i i \sum_j p(i, j)_{d,\theta};$$

$$\mu_y = \sum_j j \sum_i p(i, j)_{d,\theta};$$

$$\sigma_i = \sqrt{\sum_i (i - \mu_x)^2 \sum_j p(i, j)_{d,\theta}};$$

$$\sigma_j = \sqrt{\sum_j (j - \mu_y)^2 \sum_i p(i, j)_{d,\theta}}$$

Welch *et al.* (1990) comentam que o método de extração de textura baseada na matriz de ocorrência dos níveis de cinza exige muita memória e tempo computacional. Para diminuir esses problemas, sugere-se a extração de medidas de textura a partir dos vetores soma e diferença dos níveis de cinza. O procedimento é similar ao do método matriz de co-

ocorrência dos níveis de cinza. Para o par de níveis de cinza (i,j) são definidas as variáveis k e l, referentes ,respectivamente, à soma e à diferença de níveis de cinza i e j. Cada elemento do vetor soma é definido como:

$$P^S(k)_{d,\theta} = \sum_i \sum_j p(i, j)_{d,\theta} \quad \forall (i + j) = k \quad \text{Equação (3.17)}$$

E cada elemento do vetor diferença é definido como:

$$P^D(l)_{d,\theta} = \sum_i \sum_j p(i, j)_{d,\theta} \quad \forall |i - j| = 1 \quad \text{Equação (3.18)}$$

Soares *et al.* (1997) e Welch *et al.* (1990) apresentam a formulação matemática das medidas derivadas do vetor soma e do vetor diferença:

- Média do vetor soma

$$MS_{d,\theta} = \sum_k k P^S(k)_{d,\theta} \quad \text{Equação (3.19)}$$

- Variância do vetor soma

$$VS_{d,\theta} = \sum_k (k - MS_{d,\theta})^2 P^S(k)_{d,\theta} \quad \text{Equação (3.20)}$$

- Energia do vetor soma

$$ENES_{d,\theta} = \sum_k P^S(k)_{d,\theta}^2 \quad \text{Equação (3.21)}$$

- Entropia do vetor soma

$$ENTS_{d,\theta} = \sum_k P^S(k)_{d,\theta} \log P^S(k)_{d,\theta} \quad \text{Equação (3.22)}$$

- Média do vetor diferença

$$MD_{d,\theta} = \sum_l l P^D(l)_{d,\theta} \quad \text{Equação (3.23)}$$

- Variância do vetor diferença

$$VD_{d,\theta} = \sum_l (l - MD_{d,\theta})^2 P^D(l)_{d,\theta} \quad \text{Equação (3.24)}$$

- Energia do vetor diferença

$$ENED_{d,0} = \sum_l P^D(l)_{d,0}^2 \quad \text{Equação (3.25)}$$

- Entropia do vetor diferença

$$ENTD_{d,0} = -\sum_l P^D(l)_{d,0} \log P^D(l)_{d,0} \quad \text{Equação (3.26)}$$

- Contraste do vetor diferença

$$CON_{d,0} = \sum_l l^2 P^D(l)_{d,0} \quad \text{Equação (3.27)}$$

As dezoito medidas de textura acima citadas estão disponíveis no classificador ClaTex, implementado no SPRING, versão 4.1.

Tais medidas serão utilizadas com vistas a extrair maiores informações referentes às feições e a proporcionar melhor desempenho na acurácia da classificação das imagens.

Dentre os métodos de análise de texturas testados para a extração de informações das imagens de satélite, o mais conhecido e consolidado baseia-se na matriz de co-ocorrência de níveis de cinza. Entretanto o alto número de medidas texturais que podem ser calculados a partir da matriz de co-ocorrência, bem como a correlação entre algumas medidas, tornam o processo de seleção das medidas complexo. O desempenho de um conjunto de medidas de textura na classificação deve ser analisado individualmente para cada aplicação (Marceu *et al.*1990; Soares *et al.* 1997; Shaban e Dikshit, 1998; e Tso e Olsen, 2004).

4 – REVISÃO BIBLIOGRÁFICA

Levando-se em consideração a característica da área em estudo, cuja atividade econômica é a agricultura irrigada, inicialmente efetuou-se um levantamento bibliográfico referente ao uso do sensoriamento remoto na agricultura.

Um outro assunto envolvido com o tema em estudo é a questão da classificação das imagens. A utilização de imagens de muito alta resolução espacial, caracterizadas por proporcionar maior definição dos detalhes espaciais, pode propiciar melhor interpretação visual. Por outro lado, observa-se que a extração de grande quantidade de informações por meio de classificadores ainda não tem sido satisfatória, visto que os classificadores mais difundidos baseiam-se apenas no reconhecimento espectral.

Nas imagens de muito alta resolução espacial fica perceptível a heterogeneidade estrutural em diversas classes. Assim sendo, observa-se que para a identificação de tais classes por meio de um classificador, é relevante que este considere além da informação espectral, outras informações, como por exemplo, o reconhecimento de padrões espaciais. Com o surgimento das imagens de muito alta resolução espacial essa problemática com relação à classificação das imagens ganhou maior dimensão, despertando o meio científico para o desenvolvimento de novos classificadores que incluam as informações espaciais e de contexto.

Tendo em vista verificar o desempenho dos classificadores texturais, julgou-se pertinente fazer uma pesquisa quanto à utilização de atributos texturais.

4.1 – Aplicação do sensoriamento remoto na agricultura irrigada

Segundo Bastiaanssen *et al.* (2000) o uso do sensoriamento remoto possibilita adquirir importantes informações relacionadas aos recursos hídricos. Essas informações são potencialmente usadas em legislação, planejamento, alocação de água, avaliação de impactos, pesquisas nos campos de saúde e meio ambiente. O sensoriamento remoto tem sido capaz de proporcionar informações sobre o uso do solo, áreas irrigadas, tipos de

cultura, desenvolvimento do bioma, campos de cultura, água requerida para a cultura, evapotranspiração da cultura, salinidade e empoçamentos.

Vários trabalhos têm sido conduzidos com a utilização do sensoriamento remoto em áreas irrigadas. Dentre os trabalhos mais recentes temos o desenvolvido por Roerink *et al.* (1997) que realizaram um trabalho na bacia do rio Tunuyan, na Argentina, para verificar o consumo de água na irrigação, por meio de indicadores da evapotranspiração obtidos com o auxílio das imagens Landsat. Em relação à identificação de áreas irrigadas por meio do sensoriamento remoto, pode-se relatar as pesquisas apresentadas por Jiren *et al.* (1997) e Martínez e Calera (2001). Outro trabalho a ressaltar refere-se ao estudo para o monitoramento da água extraída do aquífero codificado como 08.29 Mancha Oriental, na Espanha, para uso na irrigação, trabalho desenvolvido por Olalla *et al.* (2003).

Esses autores fizeram a classificação das áreas irrigadas baseadas nas várias respostas espectral obtidas durante um período de tempo correspondente às evoluções temporais das culturas. O desenvolvimento das culturas foi descrito por meio do índice de vegetação por diferença normalizada (IVDN). As culturas foram agrupadas em classes de acordo com as similaridades apresentadas no desenvolvimento fenológico individual de cada cultura. As culturas pertencentes à mesma classe assumiram um valor médio de quantidade de água requerida. Combinando as informações concernentes às áreas irrigadas e ao consumo de água necessário para cada classe, foi estimado o volume de água utilizado na irrigação.

Para Bastiaanssen *et al.* (2000), as formas de uso da água estão em processo de mudança devido à crescente pressão sobre os recursos hídricos. Um planejamento estratégico quanto ao uso da água requer boas informações sobre áreas irrigadas, espécies de cultura, água evapotranspirada e histórico do uso da água. Esses autores relatam que, geralmente, as fazendas adaptam as suas práticas de cultivo fazendo uso de toda a disponibilidade de água incluindo as águas subterrâneas. Com isso, a situação real das áreas irrigadas pode não estar condizente com a situação planejada. Nesse contexto, o sensoriamento remoto apresenta-se como um excelente meio para se ajustar dentro do processo de planejamento estratégico em nível regional. Os mesmos autores ainda abordam que a outorga é o fator chave na alocação da água e na garantia de estoque por aqueles que tem o direito de uso da água. Quando estabelecido um sistema de outorga, a identificação do uso da água obtida pelo sensoriamento remoto pode ser extremamente benéfica em determinar quais são os

usuários que estão, atualmente ou historicamente, utilizando a água. Depois que os proprietários outorgados são localizados, o uso da água pode ser fiscalizado. A partir da interação entre um banco de dados geográficos de cadastro de outorga com as informações obtidas por meio do sensoriamento remoto referentes às estimativas das áreas com cobertura vegetal irrigadas, pode-se efetuar a fiscalização.

Uma outra abordagem relevante é quanto à utilização do sensoriamento remoto na agricultura de precisão. Esse sistema é baseado em novos instrumentos e fontes de informações fornecidas por novas tecnologias como: georreferenciamento por meio do GPS (sistema de posicionamento global), manipulação dos dados em ambiente SIG, projetos de monitoramento de campo e o sensoriamento remoto. O acompanhamento do desenvolvimento da cultura em tempo real e a correção dos fatores deficientes no momento em que são diagnosticados é uma das atividades mais importantes na agricultura de precisão. Uma grande demanda de pesquisa situa-se na interpretação das imagens obtidas, por sensoriamento remoto, no espectro eletromagnético visível e no infravermelho próximo, com respeito à sua correlação com os fatores de desenvolvimento da cultura. Embora o potencial do sensoriamento remoto para a agricultura esteja claramente estabelecido, sua adoção pelos fazendeiros permanece baixa. Com o surgimento das imagens de alta resolução espacial, possibilitando maior nível de detalhamento, é possível diagnosticar a situação da cultura com maior segurança (Seelan *et al.*, 2003).

4.2 - Utilização de atributos texturais na classificação de imagens

Marceu *et al.* (1990) fizeram uma pesquisa aplicando medidas texturais com o objetivo de obter um melhoramento na classificação do uso e ocupação do solo referente a uma área com diversos tipos de cobertura (campos agricultáveis, solos em pousio, áreas residenciais, tipos de florestas e solo exposto). Foram utilizadas imagens multiespectrais do SPOT, extraíndo-se características texturais a partir da banda infravermelho próximo por quatro medidas texturais: energia, entropia, homogeneidade e contraste. Os autores observaram que a adição de características texturais na classificação contribuiu para o acréscimo da sua acurácia.

Shaban e Dikshit (1998) desenvolveram um estudo em um meio urbano com imagens multiespectrais do SPOT fazendo uso da matriz de co-ocorrência para extrair

características texturais com a finalidade de se investigar o ganho de acurácia na classificação ao combinar características texturais e espectrais. Nessa classificação, composta por 21 classes foram aplicadas seis medidas texturais: energia, contraste, correlação, entropia, variância e homogeneidade. Os resultados mostraram que houve um ganho de 9% na acurácia da classificação ao combinar características texturais e espectrais quando comparadas à aplicação de apenas características espectrais.

Ruiz *et al.* (1998) utilizaram imagens Landsat TM para a discriminação de dosséis vegetais, aplicando o algoritmo máxima verossimilhança adicionado à informação textural obtida por fotografias aéreas de 4 m de resolução espacial. Oito características de textura derivadas da matriz de co-ocorrência foram extraídas. A classificação apresentou uma acurácia de 88%. Os autores comentaram que a metodologia adotada é útil para a discriminação de determinadas classes da vegetação, caracterizadas com baixa separabilidade espectral e arrançadas em pequenas unidades na floresta, aumentando o detalhe da classificação naquelas áreas de interesse particular.

Franklin *et al.* (2001) fizeram um estudo com uma imagem multiespectral CASI (*Compact Airborne Spectrographic Imager*) de 4 m de resolução espacial, para determinar se as medidas texturais de co-ocorrência contribuíam para o aumento da acurácia da classificação concernente à determinação da composição de espécies de florestas. Foram efetuados três tipos de classificações, utilizando: apenas a informação espectral; somente a informação textural, e; a combinação das informações espacial e textural. Tendo sido analisados para 33 classes, 10 classes e 6 classes. Obtiveram um melhor resultado com a combinação de dados espectrais e texturais. Para a classificação composta de 6 classes houve um aumento de 33% na acurácia devido à adição da informação textural.

Wikantika *et al.* (2002) utilizaram imagens do Landsat ETM, considerando os seus aspectos espectrais e texturais com o objetivo de discriminar campos de vegetação em áreas montanhosas. O estudo foi realizado para uma área localizada no oeste de Java, Indonésia. As características texturais foram calculadas a partir do GLCM empregando quatro medidas: contraste, média, entropia e energia. Para a classificação composta de oito classes de cobertura do solo foi utilizado o classificador máxima verossimilhança combinada às características texturais e componentes principais. Obteve-se um desempenho médio de 85,55%.

Souza *et al.* (2003) utilizaram informações texturais extraídas pela matriz de co-ocorrência visando avaliar a qualidade de imagens Ikonos para o mapeamento do uso do solo urbano. O melhor resultado de classificação – acurácia de 83% – foi obtido utilizando as seguintes medidas texturais: contraste, dissimilaridade, média do vetor diferença, variância do vetor diferença e contraste do vetor diferença referentes ao canal vermelho e homogeneidade e dissimilaridade referentes ao canal infravermelho próximo.

Lelong e Thong-Chane (2003) realizaram um estudo em imagens de muito alta resolução espacial para avaliar os possíveis ganhos de informação no mapeamento de áreas de culturas perenes (café, banana, papaya, cana-de-açúcar, batata-doce, entre outras). Oito medidas texturais foram aplicadas em duas imagens pancromáticas: uma do QuickBird (0,65 m) e outra do Ikonos (1 m). Os resultados mostraram que a acurácia da classificação para as duas imagens são similares no caso de pomares de grandes extensões, mas não para a detecção de pequenos alvos. Os autores comentaram, ainda, que a análise de co-ocorrência para esse tipo de aplicação parece promissora, mas necessita ainda alguns desenvolvimentos para integrar variações de derivação de escalas e a seleção de uma janela ótima de vizinhança para cada pixel.

Wang *et al.* (2004) compararam os resultados de classificação referentes ao mapeamento de espécies de mangues, localizadas no Caribe, aplicadas às imagens QuickBird e Ikonos. Inicialmente foram realizadas classificações utilizando apenas a informação espectral e em seguida com a inclusão da informação textural a partir das medidas estatísticas de primeira ordem e de segunda ordem, e, também a classificação orientada a objeto. Os resultados mostraram que com a inclusão de medidas de primeira ordem, tanto para a imagem Ikonos quanto para a imagem QuickBird, não ocorreram aumentos significativos na acurácia das classificações quando comparadas as classificações da máxima verossimilhança, acurácia baseada no índice Kappa. Para as medidas de segunda ordem, foram utilizadas três medidas, contraste, correlação e entropia. De acordo com o índice Kappa, os resultados mostraram que para ambas imagens a adição dessas medidas não resultou em boa acurácia na classificação. Quanto às classificações orientadas a objeto, os resultados quanto aos desempenhos médios para esse classificador foram iguais.

Sto e Olsen (2004) utilizaram imagens Ikonos multiespectral de 4 m e pancromáticas reamostradas de 1 m para 4 m. O objetivo também foi avaliar a potencialidade da discriminação no desempenho de classificação ao utilizar características texturais e

espectrais, e, analisar a acurácia da classificação ao combinar informações espectrais, texturais e de contexto. As medidas texturais foram extraídas da imagem pancromática e posteriormente combinada a imagem multiespectral utilizando o classificador da máxima verossimilhança. A fim de refinar a classificação foi considerada a informação contextual obtida por um modelo aleatório refinado denominado *Markov Random Fields* (MRF). Esse trabalho foi realizado para uma reserva natural com áreas urbanas e de uso agrícola denominada Elkhorn Slough, localizada na costa central da Califórnia, tendo sido gerada classificações com oito classes. A classificação contextual resultou em uma acurácia de 78,56% correspondendo a um aumento de 13% comparada à classificação com dados espectrais e de 5% comparada à classificação com atributos texturais e espectrais.

Vansteenkiste *et al.* (2004) elaboraram um trabalho em imagens de muito alta resolução incorporando a informação textural em três tipos de classificadores: MAP (*maximum a posteriori*), distância mínima e paralelepípedo. O estudo foi realizado em uma imagem multiespectral do Ikonos de 4 m de resolução espacial, escolhendo-se quatro áreas amostrais: campos, cidade, área urbana e rural, e floresta e cidade.

5 – MATERIAIS E MÉTODOS

5.1 – ÁREA DE ESTUDO

A sub-bacia do córrego Capão Comprido é parte integrante da bacia do Lago Descoberto. Essa bacia está inserida em duas unidades federativas, o Distrito Federal e o Estado de Goiás. Seus principais tributários são: o rio Descoberto, o ribeirão das Pedras, o ribeirão Rodeador e os córregos Chapadinha, Capão Comprido e Pulador (Campana *et al.*, 1998).

A agricultura destaca-se como uma das principais atividades econômicas da bacia, principalmente na porção do Distrito Federal. O núcleo rural abrange duas Agências de Desenvolvimento da EMATER: Brazlândia e Alexandre Gusmão.

A área de estudo (Figura 5.1) possui uma extensão de aproximadamente 16,40 km². Está localizada entre as coordenadas 15°43'42" a 15°45'41" lat. sul e 48°10'07" a 48°06'13" long. oeste de Greenwich. As cotas altimétricas variam de 1030 a 1270 metros.

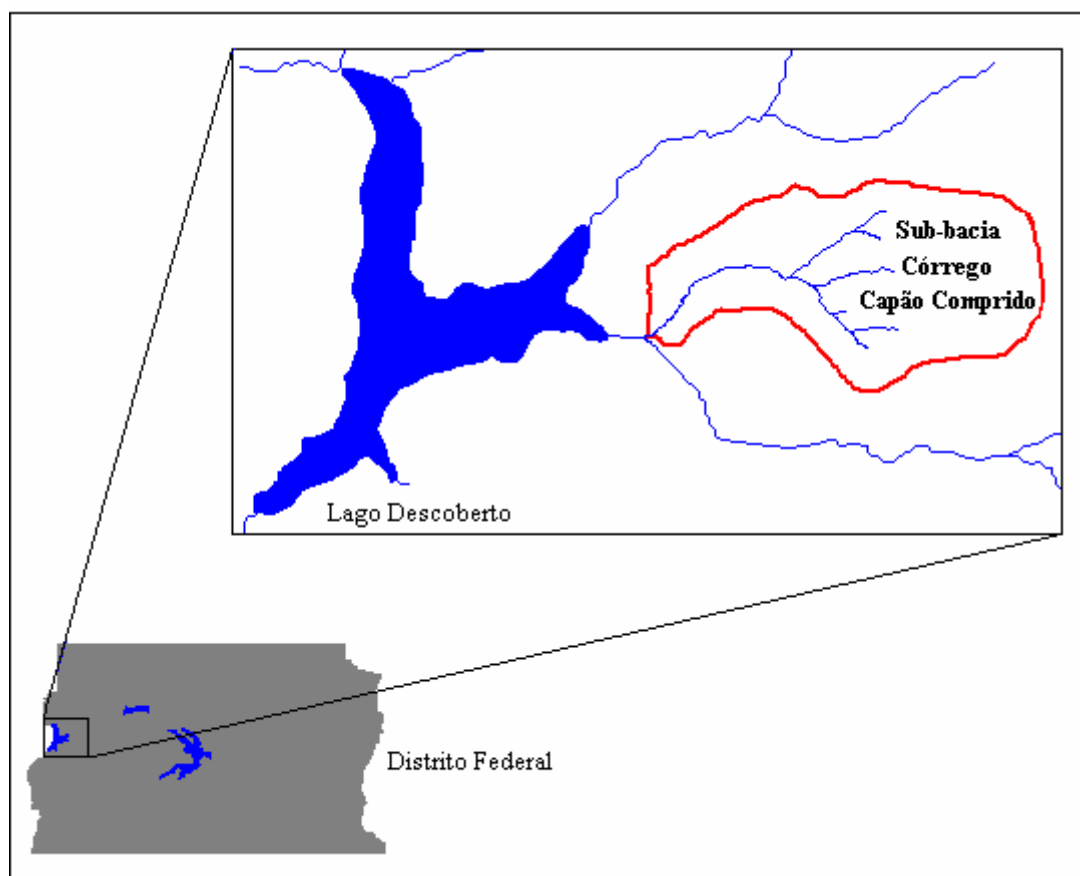


Figura 5.1- Representação da localização da sub-bacia do córrego Capão Comprido.

Estudo realizado por Reatto *et al.* (2003) a respeito dos levantamentos dos tipos de solo na bacia do lago Descoberto, mostra que, na sub-bacia em estudo, há predominância do latossolo vermelho. Segundo Lepsch (1993) trata-se de solos bastante porosos, de textura variável, com argilas de baixa capacidade de troca de cátions e fortemente intemperizados.

Quanto ao clima dessa região, típico do cerrado, é marcado pela forte sazonalidade, com dois períodos distintos bem caracterizados. No Distrito Federal se insere uma estação seca que se estende de maio a setembro, evidenciada pela baixa nebulosidade, alta taxa de evaporação e baixas umidades relativas diárias; e outra estação chuvosa entre outubro e abril, sendo que os meses de dezembro a março concentram cerca de 47% da precipitação anual (Campos, 2004).

Segundo Nascimento *et al.* (2000), a sub-bacia do córrego Capão Comprido está dentro da área de abrangência do Projeto Integrado de Colonização Alexandre de Gusmão (criado com o objetivo de abastecer o Distrito Federal com frutas, legumes e verduras). Trata-se, portanto, de uma sub-bacia predominantemente rural, caracterizada por pequenas propriedades, em média 10 hectares.

De acordo com informações obtidas na EMATER – núcleo rural Alexandre Gusmão – o uso agrícola da área em estudo caracteriza-se principalmente pelo cultivo de hortaliças e em menor concentração, o cultivo de frutas. No tocante ao método de irrigação utilizado, destaca-se o método por aspersão.

Além das atividades agrícolas com o cultivo de alface, brócolis, couve, coentro, cebolinha, rúcula, vagem, berinjela, tomate, batata-doce, goiaba, poncan, limão, etc., a cobertura do solo é composta também por mata ciliar, reflorestamento e remanescentes de vegetação do cerrado, representados por fisionomias de campo limpo, de campo cerrado e de cerrado. A Figura 5.2 ilustra alguns tipos de uso e ocupação do solo ao longo da sub-bacia do córrego Capão Comprido, cuja interpretação visual foi efetuada associando-se a uma nomenclatura (que deu margem a uma legenda), estabelecida em função da averiguação de reconhecimento da área em trabalhos de campo. Trata-se de uma composição colorida natural realçada da imagem QuickBird-2, bandas 1(B), 2(G) e 3(R) e 2,8 m de resolução espacial.




Figura 5.2 – Caracterização da sub-bacia do córrego Capão Comprido

5.2 – MATERIAIS

5.2.1- Seleção das imagens

O conhecimento prévio da época adequada para a obtenção da imagem, a escolha do satélite, as bandas a serem selecionadas (cada banda reflete uma determinada faixa do espectro), são fatores que devem ser abordados cuidadosamente, pois deles dependem o resultado.

Inicialmente o foco dessa pesquisa era avaliar superfícies irrigadas por uma imagem de alta resolução, realizando trabalho de campo próximo à data de passagem do produto a ser adquirido. Por questão de custos, foram compradas três imagens em acervo do SPOT-5, e, a partir desse momento o interesse da pesquisa, tal como apresentado nos objetivos, passou a ser a avaliação individual de cada imagem no que se refere a sua aplicabilidade para a identificação e elaboração de mapas de uso e ocupação do solo a partir da classificação textural das imagens, em uma área tipicamente rural.

Também foram adquiridas imagens em acervo do QuickBird-2. A compra dessas imagens foi motivada por um atraso que ocorreu com a entrega das imagens do SPOT-5.

Em síntese, nessa pesquisa serão utilizadas imagens de dois satélites ambientais: SPOT-5 e QuickBird-2.

Trata-se de três imagens do SPOT-5, sendo duas pancromáticas com resoluções de 2,5 metros e 5 metros e uma multiespectral de 10 metros, datadas de 02 de maio de 2004, 20 de julho de 2003 e 29 de abril de 2003, respectivamente. As duas imagens do QuickBird-2 são compostas por uma pancromática com resolução espacial de 0,70 m e outra multiespectral com resolução espacial de 2,8 m, ambas do dia 03 de agosto de 2003. Todas as imagens são quantificadas em 8 bits.

5.2.2 –Software

No que se refere às etapas integradas ao geoprocessamento, utilizou-se os seguintes aplicativos de software:

- SPRING (Sistema de Processamento de Informações Georreferenciadas), desenvolvido pelo INPE – Instituto de Pesquisas Espaciais, empregado para fazer o processamento das imagens digitais.
- ArcView da *Environmental Systems Research Institute* - ESRI, para fazer a delimitação da sub-bacia do Córrego Capão Comprido, por meio da extensão HEC-geoHMS do *US Army Corps of Engineers*.
- SKI-PRO da Leica *Geosystems*, para o pós-processamento dos pontos adquiridos com o GPS (*global position system*) Leica, modelo *System 500*, no levantamento de campo.

5.2.3 - Cartas planialtimétricas

Para a obtenção do modelo digital do terreno (MDT), foram utilizadas cartas planialtimétricas elaboradas pela Companhia de Desenvolvimento do Planalto Central (CODEPLAN), no sistema cartográfico do Distrito Federal (sistema de projeção *Universal Transversa de Mercator* – UTM, datum *South American Datum* – SAD-69, meridiano central 45° w). Trata-se de cartas em formato digital, na escala de 1:10.000 com curvas de nível equidistantes de 5 metros.

A partir do MDT produziu-se a delimitação da bacia do córrego Capão Comprido. Como as imagens foram adquiridas no sistema de projeção UTM, datum *World Geodetic System - WGS-84*, o arquivo gerado referente à delimitação da bacia (formato *shapefile*) foi convertido para essa projeção.

5.2.4 – Sistema de posicionamento global

O GPS geodésico Leica, modelo *System 500*, foi utilizado para a aquisição de coordenadas geográficas ao longo da bacia, para averiguação do registro das imagens e também para a localização de alguns pontos amostrais referentes a áreas de culturas permanentes a serem identificadas nas imagens.

Os componentes principais desse equipamento são a antena e o receptor GPS. Os componentes auxiliares são: o terminal, as baterias, os cartões de memória e os cabos.

5.3 – METODOLOGIA

O desenvolvimento do trabalho tem por finalidade a elaboração de cinco mapas temáticos de uso e ocupação do solo, para uma avaliação posterior das vantagens comparativas de cada imagem. O tratamento das imagens foi executado separadamente em cada imagem correspondente a uma resolução espacial. O procedimento adotado engloba o realce das imagens, a segmentação e a classificação textural.

5.3.1 – Trabalho de campo

No transcorrer dessa pesquisa houve várias idas a campo, realizadas em duas etapas: visitas anteriores ao recebimento das imagens, para um prévio reconhecimento da área, fazendo contato com alguns proprietários para se ter uma descrição dos principais tipos de cultivos e método de irrigação utilizado, procurando obter informações referentes ao que se cultivava nos períodos próximos às datas das imagens de satélites. Adquiridas as imagens, realizou-se uma interpretação visual, e então, definiu-se os locais para aquisição de coordenadas geográficas, optando-se por áreas de culturas permanentes. Essa escolha foi motivada pela baixa variabilidade espaço-temporal, característica dessas culturas. A partir desse pressuposto, seria possível coletar os pontos dessas áreas amostrais e utilizá-los

como referência na avaliação da influência espacial das imagens na determinação dessas superfícies. Essa preocupação foi motivada pelo fato do trabalho de campo ser realizado em época distinta às datas das imagens. Alguns pontos não foram coletados por corresponderem a áreas de culturas já abandonadas. Em outras duas propriedades a aquisição dos pontos com o GPS não pode ser realizadas por falta de autorização dos proprietários. Todos os locais visitados foram fotografados. A fim de ilustrar a descrição de uso e ocupação do solo da área em estudo, selecionou-se algumas fotos (ver Apêndice B).

5.3.2 – Entrada dos dados

O processamento das imagens foi executado no SPRING. A entrada dos dados nesse software requer, inicialmente, a criação e a definição da modelagem de um banco de dados. Essa modelagem refere-se à especificação de categorias e classes (se for temático) ao qual os dados estarão associados. Em seguida, é necessária a definição do projeto – local de armazenamento dos dados utilizados e manipulados. Nessa etapa, são definidos os limites geográficos da área em estudo e a projeção cartográfica de trabalho.

Segundo o INPE (2004), os modelos disponíveis no SPRING são:

- Imagem – para dados provenientes de sensoriamento remoto em formato matricial;
- Numérico – referente a dados que possuem uma variação contínua de seus valores numéricos em função de sua posição na superfície;
- Temático – atribuído a dados que classificam uma posição geográfica quanto a um determinado tema;
- Classes – no caso de categorias de dados do modelo temático é necessário definir as classes temáticas;
- Objeto – referente à especialização de um tipo de objeto geográfico;
- Rede – atribuído aos dados geográficos que possuem relações de fluxo e conexão entre os inúmeros elementos que se deseja representar e monitorar;
- Não-Espacial – para dados que não possuem representação espacial .

É importante comentar que em geoprocessamento, ao se trabalhar com vários produtos referentes a uma mesma área, deve-se atentar para o sistema de projeção cartográfica

desses dados. Para se permitir uma compatibilidade entre os dados apresentados por cada produto, faz-se necessário definir qual o sistema de referência a ser adotado.

No que diz respeito às imagens de trabalho, tanto as imagens do SPOT-5 quanto as do QuickBird-2 foram recebidas georreferenciadas. Apesar de estarem no mesmo sistema de projeção (UTM), datum WGS-84, verificou-se que as imagens do SPOT-5 encontravam-se no meridiano central 45°w e as do QuickBird-2 no meridiano central 51°w. Tal fato ocorreu devido às cenas das imagens do SPOT-5 cobrirem uma área bem maior no meridiano central 45°w e pequena parte no meridiano central 51°w. Com relação às imagens do QuickBird-2, como a cena (25 km²) recortava praticamente a área da bacia (~16 km²), a mesma foi recebida no meridiano central 51° w.

Os pontos coletados com o GPS indicavam meridiano central 51°w e, por esse motivo, optou-se em trabalhar nesse meridiano. Inicialmente, executou-se apenas a conversão do fuso na imagem do SPOT-5. No entanto, verificou-se que havia um pequeno deslocamento no posicionamento das coordenadas comparadas às coordenadas das imagens do QuickBird-2. Para solucionar esse problema efetuou-se um novo registro nas imagens do SPOT-5, dentro do aplicativo SPRING, utilizando-se como referência as imagens do QuickBird-2.

O registro foi realizado utilizando a transformação polinomial de 1º grau, com oito pontos de controle. O maior erro médio foi de 2,78 m para a imagem multiespectral do SPOT-5.

A próxima etapa foi a criação dos projetos de trabalho. Em um primeiro momento, gerou-se um banco de dados e dentro deste, dois projetos, cada um correspondendo a um tipo de satélite. Para a importação dos dados matriciais, criou-se dentro da categoria imagem as classes SPOT e QuickBird.

Os projetos foram criados com a projeção cartográfica UTM, WGS-84, meridiano central 51° w, sistema de referência adotado como padrão no desenvolvimento dessa pesquisa, trabalhando-se com o retângulo envolvente 803400 m e 8.255300 m (canto inferior esquerdo) e 810400 m e 8.259100 m (canto superior direito).

Com o intento de trabalhar apenas com a área correspondente à sub-bacia do córrego Capão Comprido, efetuou-se o recorte das imagens a partir do polígono referente à delimitação da sub-bacia.

5.3.3 - Definição das classes de uso do solo

Com base no reconhecimento da área de estudo por meio de visitas a campo, do auxílio da base cartográfica e da interpretação das imagens disponíveis, foram identificados os usos predominantes na bacia, tendo sido definidas as seguintes classes:

- Cobertura natural de porte arbóreo (denominada de mata para a legenda): incluindo mata ciliar caracterizada por formações úmidas, densas, fechadas, predominantemente arbóreas, que acompanham os cursos d'água e outras regiões de árvores de grande porte constituindo áreas de densa cobertura vegetal.
- Cerrado: vegetação com fisionomia dominada por árvores, com sinúsias arbóreas, arbustivas e herbáceas diferenciadas.
- Campo limpo: predomínio de estrato herbáceo, praticamente inexistindo os outros;
- Campo cerrado: de origem natural ou antrópica, as formações campestres são áreas com predomínio absoluto de espécies herbáceas e algumas arbustivas;
- Horticultura 1: talhões com plantação de hortaliças em desenvolvimento vegetativo inicial, com pouca cobertura do solo.
- Horticultura 2: talhões com plantação de hortaliças em estágio fenológico de intermediário a final, predominando a cobertura dos talhões pelas culturas.
- Fruticultura: plantações de goiaba, poncan e coco.
- Solo exposto: incluindo solos “presumidos” em pousio.
- Áreas construídas: galpões e casas presentes na bacia.
- Reservatórios de água: presentes em algumas chácaras para a regularização da irrigação.
- Reflorestamento: áreas cobertas por eucaliptos;
- Estradas pavimentadas;
- Estradas sem pavimentação.

5.3.4 – Manipulação das imagens

No que se refere à manipulação das imagens, utilizou-se o programa SPRING. A escolha deste software para o trabalho de processamento de imagens digitais foi motivada pela sua distribuição gratuita e por ser de tecnologia brasileira, com vistas a contribuir no âmbito científico no que se refere a sua aplicabilidade para imagens de alta e muito alta resolução espacial. O estudo ficou direcionado na análise da utilização das medidas de Haralick para a extração de atributos texturais das imagens na execução da classificação.

Como explanado anteriormente, pretende-se obter como resultado final mapas temáticos gerados a partir da classificação textural das imagens e posteriormente compará-los, buscando analisar a qualidade dos mapas temáticos gerados para a determinação das classes de uso e ocupação do solo em áreas tipicamente rurais.

O surgimento de novos produtos, caracterizados pela muito alta resolução espacial, tem gerado expectativas quanto à capacidade desses produtos na melhora da determinação dos alvos pelos algoritmos de classificação, visto que essas imagens são consideradas de baixa qualidade espectral, e a maioria dos classificadores, os convencionais, baseia-se apenas no reconhecimento espectral pixel a pixel.

De acordo com alguns pesquisadores (Gong e Howarth, 1990; Barnsley e Barr, 1996) a classificação de imagens de alta resolução espacial por classificadores tradicionais pixel a pixel não apresentam necessariamente uma melhor precisão, podendo até apresentar redução na precisão. O aumento da resolução espacial gera uma maior heterogeneidade estrutural na imagem, visto que um maior número de elementos individuais é detectado. Tal detalhamento, caracterizado por um alto número de pixels, bem como variada resposta espectral entre os pixels de uma mesma região, tornam o processo de treinamento mais complexo e classificação pixel a pixel mais problemática.

A classificação textural baseia-se nas características espectrais e na informação espacial dos níveis de cinza. Vários autores (Vansteenkiste *et al.* 2004; Morales *et al.* 2003; Berberoglu *et al.* 2000; Fukue *et al.* 1998; Carr, 1996) comentam que os algoritmos de classificação que utilizam atributos texturais resultam em acurácia de classificação maior do que a gerada por classificadores baseados apenas na informação espectral.

O classificador ClaTex, implantado no SPRING, utiliza atributos texturais. Trata-se de um algoritmo supervisionado, aplicado sobre imagens segmentadas. Com isso, os resultados obtidos na etapa de segmentação, anterior à classificação, precisam ser cuidadosamente analisados. Esse classificador proporciona a extração de textura a partir de medidas estatísticas de primeira ordem e de segunda ordem. Para a classificação das imagens, utilizou-se o grupo referente às medidas de Haralick, cuja extração das características texturais é derivada da matriz de co-ocorrência de níveis de cinza.

5.3.4.1 – Interpretação das imagens

Nesta subsubseção é dado um enfoque às imagens multiespectrais.

A fim de se obter composições coloridas que melhor discriminassem as feições de interesse, facilitando a interpretação visual, fez-se a leitura da variância correspondente a cada banda espectral (Tabela 5.1) e, para cada imagem multiespectral, gerou-se a matriz de correlação entre as bandas (Tabela 5.2).

Tabela 5.1 – Valores da variância das bandas espectrais correspondentes às imagens multiespectrais do SPOT-5 e QuickBird-2.

SPOT-5	QuickBird-2
Banda 1(verde) – 141,96	Banda 1(azul) – 556,96
Banda 2 (vermelho) – 535,33	Banda 2 (verde) – 503,52
Banda 3 (infravermelho próximo) – 295,52	Banda 3 (vermelho) – 665,05
Banda 4 (infravermelho médio) – 241,59	Banda 4 (infravermelho próximo) – 1439,50

Tabela 5.2 – Matrizes de coeficiente de correlação para as imagens multiespectrais do SPOT-5 e do QuickBird-2.

Multiespectral do SPOT-5					Multiespectral do QuickBird-2				
Bandas	1	2	3	4	Bandas	1	2	3	4
1	1				1	1			
2	0,992	1			2	0,967	1		
3	0,959	0,982	1		3	0,961	0,892	1	
4	0,949	0,948	0,904	1	4	0,985	0,976	0,945	1

O conhecimento dos valores de variância também será importante na hierarquização das bandas espectrais a serem utilizadas na etapa de segmentação. Esse foi um critério estabelecido na tentativa de otimização do procedimento de segmentação e sua abordagem é descrita adiante.

Para as duas imagens multiespectrais, selecionou-se as bandas verde, vermelho e infravermelho próximo, obtendo-se composições coloridas satisfatórias para fins de interpretação visual.

Almejando-se a uma identificação mais detalhada das feições, selecionou-se as bandas espectrais da composição colorida da imagem do QuickBird-2 com 2,8 m de resolução espacial e a banda pancromática com 0,70 m de resolução espacial, executando-se a fusão dessas bandas, e obtendo-se como resultado uma composição colorida de 0,70 m de resolução espacial (Figura 5.3).

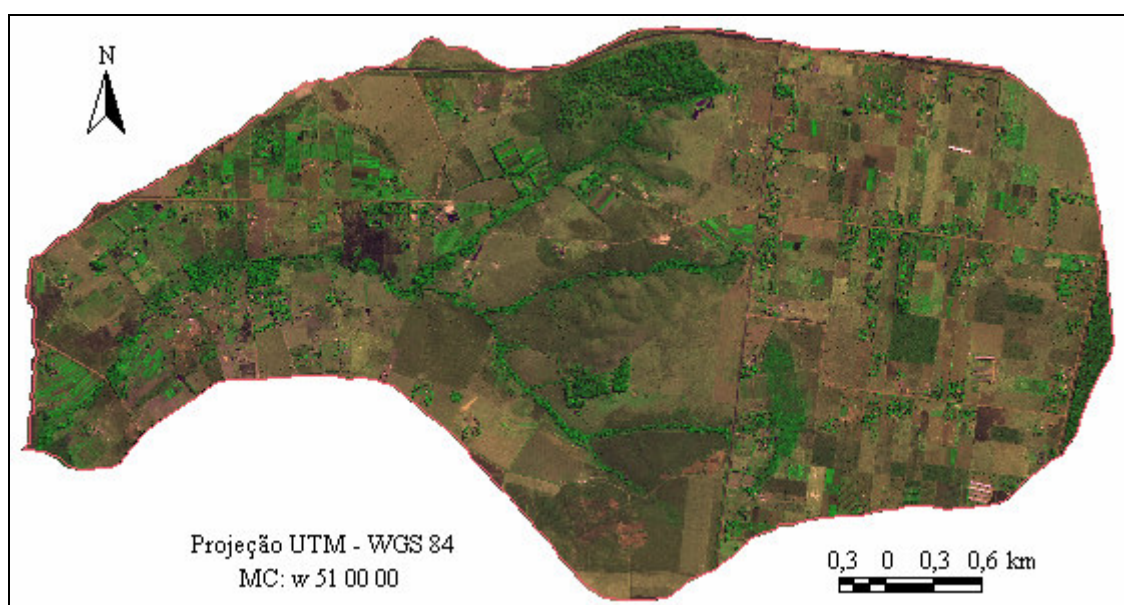


Figura 5.3 – Composição colorida com 0,70 m de resolução espacial, obtida pela fusão das bandas multiespectrais 2, 3 e 4 e pan, todas do QuickBird-2.

No SPRING esse procedimento é realizado, selecionando-se as bandas espectrais da composição colorida, transformando-as em IHS e ao se efetuar a transformação inversa IHS→RGB, a componente I referente ao brilho é substituída pela banda pancromática, obtendo-se o resultado mencionado.

A imagem fundida foi utilizada como referência na identificação das feições, auxiliando, principalmente, na escolha das amostras representativas, na fase de treinamento das imagens pancromáticas, dada à dificuldade de distinção entre alguns tipos de cobertura devido à semelhança entre as respostas espectrais.

5.3.4.2 – Segmentação das imagens

O classificador ClaTex do SPRING requer uma imagem rotulada para a extração das amostras representativas de cada classe. A classificação das outras regiões como pertencente a uma das classes em questão é efetuada utilizando-se como regra de decisão a distância de Mahalanobis.

Para segmentar as imagens, utilizou-se a técnica de crescimento por regiões, que consiste em subdividir a imagem em áreas homogêneas, a partir dos limiares de similaridade espectral e de área mínima em pixels. O resultado da segmentação é uma imagem rotulada composta de contornos das regiões delimitadas. Efetuando-se a sobreposição dessa imagem segmentada a outras imagens, é possível identificar melhor os alvos nas imagens, facilitando a escolha das amostras na etapa de treinamento.

Cabe lembrar que o trabalho de segmentação foi executado separadamente para cada imagem utilizando as bandas originais: três do SPOT-5, sendo duas pancromáticas e uma multiespectral, e duas do QuickBird-2, uma pancromática e a outra multiespectral. Destaca-se que para cada imagem foram testadas diversas combinações de limiares de similaridade e tamanho de área, para melhor delineamento dos alvos.

Tal procedimento pôde ser realizado considerando-se uma banda ou uma combinação de bandas.

Assumindo-se que o contraste apresentado em uma banda espectral pode ser associado à medida de variância desta, tem-se que quanto maior a variância maior o contraste, sendo mais perceptível a discriminação das feições. Por tal motivo, no caso dos produtos multiespectrais, inicialmente, selecionou-se para a segmentação a banda com maior variação tonal, dentre as bandas utilizadas na composição colorida. A intenção de se executar esse procedimento, em somente uma banda, foi de otimizar o processo de

segmentação, visto que o tempo de execução aumenta de acordo com o número de bandas utilizadas. Selecionou-se a banda de maior variância buscando-se a maior quantificação dos delineamentos das feições representativas.

Primeiramente foram segmentadas as imagens do SPOT-5. Ao comparar os resultados obtidos referentes a um delineamento satisfatório para cada imagem, observou-se que várias áreas, principalmente de talhões, não estavam igualmente delimitadas, ou até mesmo não delimitadas. Tal fato pode ser atribuído a três fatores: diferença na resolução espacial, variabilidade temporal e/ou baixo contraste entre esses locais e a vizinhança.

Como o objetivo principal dessa pesquisa é fazer uma comparação entre os mapas temáticos obtidos por cada imagem correspondente a uma resolução espacial diferente e a classificação requer a segmentação de regiões para a coleta de amostras na fase de treinamento, o ideal é que a delimitação das áreas nas diversas imagens seja equivalente.

Procurando analisar melhor o efeito da resolução temporal em imagens com resolução espacial diferentes, selecionou-se a imagem SPOT-5 pancromática de 5 m para ser reamostrada para 10 m e 2,5 m, pois esta correspondia a uma data mais próxima às imagens do QuickBird-2, havendo uma diferença temporal de apenas 13 dias.

No SPRING é possível executar a reamostragem utilizando a ferramenta “restaurar”. No entanto, isso só acontece para imagens cujas características, radiométrica e espacial, não tenham sido alteradas. Nesse caso, as imagens do SPOT-5 não puderam ser reamostradas no SPRING.

O módulo IMPIMA do produto SPRING tem como função principal a leitura de imagens. A partir dessa função, é possível mudar a resolução espacial da imagem por meio do fator de amostragem, porém limitado à geração de imagens com resolução espacial menor que a original. Assim, a imagem do SPOT-5 pancromática de 5 m só pode ser reamostrada para 10 m.

Devido à dificuldade em se encontrar bibliografia que melhor aborde a questão dos limiares de similaridade para imagens de resolução espacial diferentes, procurou-se fazer uma análise dessa questão para cada tipo de satélite. Partindo do princípio que a maior

influência no resultado das segmentações era a diferença das datas e prevalecendo a intenção de fazer um comparativo dessas imagens a partir de diferentes resoluções, fez-se, também, a reamostragem da imagem SPOT-5 pancromática 2,5 m para 5 m e 10 m, obtendo-se três imagens com resolução espacial diferentes, para uma mesma data. Totalizam assim oito imagens, conforme Tabela 5.3.

Tabela 5.3 – Imagens originais e reamostradas dos satélites SPOT-5 e QuickBird-2.

	Imagens originais	Imagens reamostradas	Data
SPOT-5	multiespectral 10 m	–	29/04/03
	pancromática 5 m	pancromática 10 m	20/07/03
	pancromática 2,5 m	pancromáticas 5 m e 10 m	02/05/04
QuickBird-2	multiespectral 2,8 m	–	03/08/03
	pancromática 0,70 m		

A partir desses produtos, executou-se as segmentações dessas imagens separadamente.

Em se tratando das imagens multiespectrais, como mencionado anteriormente, iniciou-se a segmentação na banda de maior variação tonal. Como algumas feições, consideradas representativas não foram delineadas utilizando-se apenas essa banda, executou-se, então, a combinação de bandas a fim de se obter melhores delineamentos.

A princípio, essa etapa consistiu em analisar a questão da padronização de limiares para as seguintes situações:

- 1- Imagens de mesma data com resolução espacial diferente;
- 2 - Imagens de datas diferentes com mesma resolução espacial.

Para a análise do primeira situação, escolheu-se as imagens correspondentes ao dia 02/05/04 referente ao SPOT-5 (pancromática de 2,5 m e as imagens pancromáticas de 5 m e 10 m, ambas obtidas pela reamostragem da imagem pancromática de 2,5 m), e ao dia 03/08/04 referente ao QuickBird-2.

Quanto à segunda situação, utilizou-se as imagens com 10 m de resolução espacial: as multiespectrais e as duas pancromáticas, uma resultante da reamostragem efetuada na pancromática de 2,5 m e a outra na pancromática de 5 m de resolução espacial.

5.3.4.3 – Classificador ClaTex

O Classificador ClaTex reconhece a variação espacial da intensidade dos níveis de cinza da imagem para uma dada faixa espectral.

Esse método de classificação utiliza a imagem previamente segmentada na fase de treinamento para auxiliar na escolha das amostras e as medidas de textura são calculadas para as regiões amostradas.

Trata-se de um classificador supervisionado, que diferencia-se dos outros algoritmos supervisionados pelo acréscimo de duas etapas: definição de camadas e seleção da medida ou das medidas estatísticas que serão adotadas. Definir uma camada significa definir a banda espectral que contém as medidas de textura que serão submetidas às avaliações das medidas estatísticas selecionadas. Como citado anteriormente, esse classificador é dividido em cinco grupos de medidas estatísticas. Neste trabalho foram usadas as medidas de Haralick.

Sintetizando o funcionamento do classificador ClaTex, tem-se que esse algoritmo utiliza atributos texturais dos polígonos da imagem segmentada para efetuar a classificação por regiões. A classificação é realizada pela técnica de agrupamento de pixels para a formação de polígonos a partir de uma medida de similaridade entre elas. A medida de similaridade utilizada consiste na distância de Mahalanobis entre a classe de interesse e as regiões candidatas à relação de pertinência com esta classe. Portanto, cada região será vinculada a uma dada classe de interesse baseando-se na minimização da distância de Mahalanobis (INPE, 2004).

Em se considerando a utilização das medidas de Haralick no SPRING, tem-se que para uma camada, podem ser formados diversos conjuntos de medidas de textura a partir das 18 medidas estatísticas disponíveis. Além disso, para o conjunto de medidas selecionadas, pode-se definir a quantização dos níveis de cinza (1, 2, 4, 8, 16, 32, 64, 128, 256, 512) e também o tamanho da janela, variando de 3x3 a 9x9 pixels. O arquivo textura, utilizado para a classificação, pode ter uma camada ou várias camadas.

Para diminuir o tempo computacional durante o processo de classificação, esse classificador possui uma ferramenta que faz a seleção automática das medidas. O critério de decisão para a seleção de uma ou mais medidas é baseado em um fator discriminante que avalia a separabilidade entre duas classes. Sendo assim, para cada combinação entre duas classes haverá uma medida que maximiza a discriminação entre elas. O conjunto de medidas de textura utilizado para a classificação está composto pelas medidas que geraram maior fator discriminante entre cada par de classes.

Previamente à coleta das amostras de treinamento, efetuou-se o realce nas imagens a partir da técnica “contraste linear”, buscando melhor discriminação dos alvos.

Ao iniciar a etapa de classificação utilizando as medidas de Haralick foram definidos os parâmetros a serem utilizados. O procedimento é necessário devido à larga variação e possibilidade de combinações para a extração das características texturais.

Calcularam-se as medidas de textura com a adoção dos seguintes parâmetros:

- Camada correspondente à banda espectral com maior variância;
- Quantização de 128 níveis de cinza (valor inserido automaticamente na janela de seleção das medidas);
- Tamanho da janela da matriz de co-ocorrência de 3x3 pixels.

Vale a ressalva de que para a adoção de tais parâmetros, previamente, foram testados o tamanho das janelas e a quantização dos níveis:

- Tamanho da janela: para as janelas 5x5 e 7x7, obteve-se pior classificação ao se comparar seu resultado ao da janela 3x3. No caso da janela 9x9, o processamento foi interrompido, com notificação do sistema operacional de falta de memória;
- Quantização: também foram testados para 256 e 64 níveis de cinza. Os desempenhos médios de classificação para ambos os casos decaíram.

Ainda com relação ao cálculo da matriz de co-ocorrência, adotou-se o deslocamento omnidirecional, no qual o nível de cinza dos pixels de referência é comparado com os níveis de cinza dos 8 pixels vizinhos. A matriz de co-ocorrência final é formada pela média dos valores das matrizes calculadas para cada direção.

O trabalho de classificação nas diferentes imagens, utilizando atributos texturais extraídos a partir da matriz de co-ocorrência de níveis de cinza, foi dividido em três partes, conforme as análises de interesse: avaliar a potencialidade da classificação nas imagens multiespectrais e pancromáticas; verificar a influência da resolução espacial no mapeamento de uso e ocupação; e avaliar a exatidão da classificação nas diferentes imagens. O procedimento adotado para cada objetivo mencionado é apresentado nas subsubseções seguintes.

5.3.4.4 – Classificação das imagens multiespectrais

O processo de classificação foi iniciado na imagem multiespectral de 10 m de resolução espacial. Efetuou-se uma composição colorida RGB de falsa cor formada pelas bandas 2, 3 e 1. Para melhor visualização dos alvos, aplicou-se a técnica de contraste nas bandas. O resultado é ilustrado na Figura 5.4.




Figura 5.4 – Imagem multiespectral do SPOT-5, composição colorida realçada:R(banda2)G(banda3)B(banda1).

Posteriormente, iniciou-se a segmentação. O algoritmo de segmentação por crescimento de regiões do aplicativo SPRING, foi executado utilizando-se as bandas 1, 2 e 3, separadamente e em conjunto. Foram testadas diversas combinações entre os limiares de similaridade e tamanho da área, optando-se por aquela que resultou na maior discriminação dos talhões.

Escolhida a imagem segmentada, iniciou-se a classificação. Nessa etapa, foram definidas as bandas que fariam parte do processo de classificação por regiões, sendo selecionadas as bandas 1, 2, 3 e a imagem segmentada. Em seguida executou-se a etapa de treinamento, utilizando-se como referência para a identificação das superfícies a imagem fundida de 0,70 m do QuickBird.

Obtidas as amostras das classes, tem-se como etapa seguinte, a seleção da banda espectral ou das bandas espectrais que serão submetidas ao cálculo da medida de textura ou do grupo de medidas de textura. Trata-se de um procedimento trabalhoso, haja vista a dificuldade em se saber quais as melhores medidas, pois não há uma etapa prévia à classificação final que permita avaliar o desempenho das medidas de textura, e identificar quais são as que contribuem para uma melhor discriminação das classes. Nesse caso, o critério adotado para a avaliação das melhores medidas de textura é definido pelo resultado do desempenho médio da classificação obtido por meio da matriz de confusão.

Inicialmente, testou-se todas as medidas, individualmente, com os parâmetros definidos acima, na banda 2 (imagem com maior variância). Posteriormente, selecionou-se conjuntos de medidas, porém não se obteve resultado satisfatório quanto ao desempenho médio da classificação, critério assumido para a amarração das melhores medidas texturais. Tal afirmação refere-se à utilização de uma única camada, a banda de maior variância.

Devido à dificuldade na seleção das medidas de textura que resultasse em um bom desempenho médio na classificação, analisou-se adicionalmente as 18 medidas em separado para as bandas 1 e 3, com quantização de 128 níveis e janela de 3x3 pixels. Com isso, obteve-se um total de 54 resultados de desempenho médio de classificação (ver Apêndice C).

Na análise individual das medidas texturais, observou-se que nem todas resultaram em um bom desempenho médio de classificação na camada referente à banda espectral com maior variância (banda 2). Porém os maiores desempenhos médios de classificação foram obtidos para essa banda

Inicialmente, efetuou-se combinações entre as medidas que resultaram em bons desempenhos individualmente. Entretanto constatou-se que esse critério não implicou em

melhores resultados. Segundo Soares *et al.*(1997) e Ulaby *et al.*,(1983), algumas medidas estatísticas de Haralick são correlacionadas e sendo assim, a depender da seleção das medidas a serem utilizadas em conjunto, o resultado da classificação poderá não ser satisfatório.

Diante das observações citadas, adotou-se o seguinte procedimento: seleção das 18 medidas individualmente a partir da banda de maior variância, adotando-se aquele que resultou em maior desempenho médio de classificação; em seguida, seleção de outra medida que junto com a primeira selecionada resultou em um maior desempenho médio de classificação. Esse procedimento foi repetido até não haver melhora no desempenho médio da classificação ao acrescentar outra medida na camada de textura em questão. Posteriormente, acrescentou-se outra camada de textura e para esta a inserção de medidas de textura com o intuito de obter maior desempenho médio da classificação. O processo foi finalizado quando não mais se verificou ganho na acurácia da classificação.

Quanto à imagem multiespectral do QuickBird-2, efetuou-se a composição colorida b2 (B), b3(G) e b4(R), aplicando-se a técnica de realce para uma melhor qualidade visual. O resultado da composição colorida é mostrado na Figura 5.5.

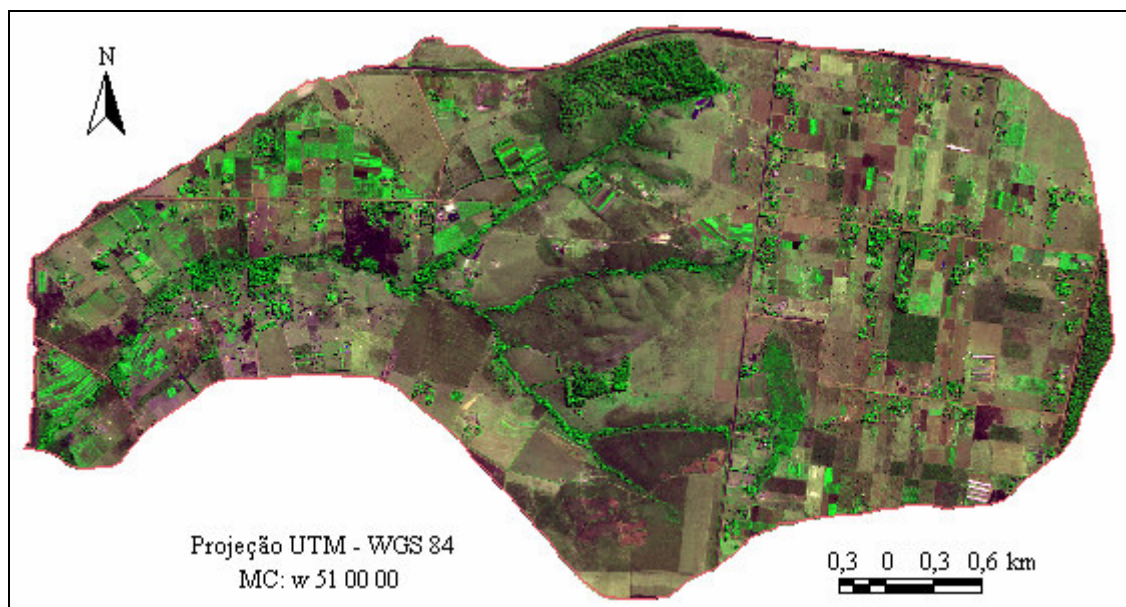


Figura 5.5 - Imagem multiespectral do QuickBird-2, composição colorida realçada R(banda3)G(banda4)B(banda2).

No que diz respeito à classificação adotou-se o mesmo procedimento efetuado na imagem multiespectral do SPOT-5 para a imagem multiespectral do QuickBird-2 e demais imagens referentes a outras avaliações.

5.3.4.5 – Classificação das imagens pancromáticas

Outro estudo de interesse, em imagens de alta resolução espacial, concerne ao uso de bandas pancromáticas na discriminação de uso e cobertura do solo.

Em relação à interpretação visual das imagens originais do SPOT-5, pan 5 m e pan 2,5 m, mesmo aplicando a técnica de realce, não houve melhora suficiente para a identificação das superfícies, decorrente, principalmente, da semelhança entre os padrões de reflectância das feições.

Apesar desse fato, buscou-se avaliar qual o desempenho do classificador Clatex nas imagens pancromáticas.

Selecionou-se, primeiramente, a imagem pancromática de 2,5 m, visto que esta possui um maior contraste, e, também, melhor resolução espacial, características favoráveis a uma boa classificação.

Ao longo da seleção das amostras, utilizou-se como referência a imagem fundida de 0,70 m do QuickBird-2, pois como descrito anteriormente, verificou-se que a limitação espectral dificultou a identificação das feições.

Conduziu-se, também, um estudo quanto à influência da resolução espacial na acurácia da classificação textural. Dessa forma, propôs-se uma comparação entre imagens de diferentes resoluções espaciais, com idêntica banda espectral e data de imageamento. Neste sentido, foram utilizadas as imagens pancromáticas de 2,5 m, também reamostrada para 5 m e 10 m.

Quanto à imagem pan 0,70 m do QuickBird-2, não se executou a classificação textural, devido ao comprometimento da seleção das amostras causada pela insatisfatória segmentação da imagem.

5.3.4.6 – Quantificação dos erros relativos na medição de áreas das classes temáticas

Com a finalidade de analisar os erros de classificação em cada imagem, quantificou-se as áreas da sub-bacia do córrego Capão Comprido, efetuando-se a edição vetorial dos polígonos pertencentes a cada alvo (classe), com base no reconhecimento de campo e interpretação visual da imagem de composição colorida de 0,70 m de resolução espacial do QuickBird-2. Os polígonos que delimitam as classes interpretadas dessa área foram utilizados como realidade de uso e cobertura do solo da sub-bacia, ou seja, verdade terrestre. Atribuiu-se a essa classificação a referência para a verificação da qualidade dos mapas temáticos gerados pelas classificações. Portanto, para cada mapa temático gerado pelo procedimento de classificação das imagens – classificador ClaTex – obteve-se as medidas de áreas correspondentes a cada classe.

De posse das áreas calculadas de cada classe, referentes à classificação de cada imagem e à verdade terrestre, efetuou-se o cálculo do erro relativo gerado pela classificação de cada classe, para cada mapa temático.

$$\varepsilon(\%)_i = \frac{A_{\text{classificada } i} - A_{\text{referência } i}}{A_{\text{referência } i}} \times 100\% \quad \text{Equação 5.1}$$

Onde:

i – 1,2,...,n; número de classes;

$\varepsilon(\%)$ - percentual do erro relativo para a classe i ;

$A_{\text{classificada } i}$ - área classificada para a classe i ;

$A_{\text{referência } i}$ - área de referência para a classe i .

Paralelamente à comparação entre as medições de áreas entre a verdade terrestre e a classificação para cada produto, realizou-se a análise visual, buscando, em uma visão geral, identificar os problemas de classificação que ocorreram para cada produto.

5.3.4.7 – Avaliação detalhada da classificação em uma área amostral

Tem-se conhecimento que a maior diferença temporal, referindo-se às imagens utilizadas nessa pesquisa, é de aproximadamente um ano. Esse período seria curto para a detecção de

mudanças, caso não se tratasse de uma área tipicamente rural, cuja característica principal é a variabilidade espaço-temporal do uso da terra.

Em função desse panorama, escolheu-se uma área amostral, pertencente à sub-bacia, que apresentasse características similares em todas as imagens, a fim de possibilitar uma comparação nas classificações obtidas por cada imagem, buscando promover uma avaliação quanto à precisão na quantificação das áreas referentes às classes temáticas.

Trata-se de uma classificação singular, cuja área selecionada possui alvos bem definidos, o que viabiliza a uma avaliação detalhada no que se refere aos resultados de classificação obtidos.

Como citado na subseção 5.3.1, definiu-se os locais para a aquisição das coordenadas geográficas durante o levantamento de campo, optando-se por áreas de culturas permanentes.

Durante a escolha da área amostral para a execução da avaliação mencionada, atentou-se para um local que abrangesse culturas permanentes visitadas com as coordenadas limítrofes coletadas com GPS, e, circundadas por outros tipos de uso e cobertura do solo. Isso permitiu realizar uma análise da precisão das superfícies classificadas, ao se comparar com a referência de campo adquirida com o GPS. Paralelamente, realizou-se uma avaliação do desempenho desse algoritmo na classificação de uma área caracterizada, também, por outros tipos de uso e cobertura do solo.

Para essa situação, que contemplou uma pequena porção da sub-bacia, não foi adotada a legenda padronizada para as classificações das imagens referentes à área total da sub-bacia em estudo.

Na classificação da área amostral, utilizou-se as seguintes classes: mata ciliar, horticultura 1, fruticultura, campo cerrado, campo limpo, solo exposto, parcela em pousio e reservatórios.

Na classificação da cena total, a classe parcela em pousio está inserida na classe solo exposto. Optou-se por essa junção, visto que houve dificuldades em diferenciar tais classes

por meio da interpretação visual. Nessa outra situação, devido ao conhecimento de campo da área amostral, fez-se à separação destas classes.

No que concerne à imagem pancromática de 2,5 m deve-se comentar que apesar da boa resolução espacial, houve dificuldade na interpretação visual de duas classes: reservatórios e horticultura 1. Nesse caso, a obtenção de informações correspondentes a essa área foi essencial para se decidir na adoção ou não de tais classes durante a classificação da imagem em questão. Em se tratando da área referente à horticultura 1, por meio da interpretação visual, observou-se que a sua tonalidade apresentou-se muito similar à da mata ciliar. Com relação à área dos reservatórios, pela interpretação visual dificilmente se afirmaria tratar-se de reservação de água, haja vista a tonalidade muito próxima à de outras feições.

Segundo informações adquiridas *in loco* na amostra considerada a área correspondente à horticultura 1 havia sido abandonada, sem plantio, no final de 2003. Por esse motivo, não se utilizou a classe horticultura 1 na classificação, visto que essa imagem é de 2004. Quanto aos reservatórios, estes sempre estiveram em funcionamento. A partir dessa informação, manteve-se a classe reservatórios para a classificação.

A partir dos pontos adquiridos com o GPS, calculou-se a área dessas culturas, obtendo assim a quantificação da verdade de campo. Por amarração desses polígonos sobre a imagem fusionada, quantificou-se as demais áreas.

Cumprir destacar que na classificação, ao longo da fase de treinamento, procurou-se escolher os mesmos locais de aquisição das amostras nas diferentes imagens.

De posse das imagens classificadas, efetuou-se a transformação destas em imagens temáticas para se obter os valores de áreas de cada classe temática. Promoveu-se, em seguida, uma comparação de quantificação de áreas entre os resultados obtidos por cada imagem.

6 – RESULTADOS E DISCUSSÃO

Neste capítulo serão apresentados e analisados os resultados obtidos durante o processo de classificação das imagens do QuickBird-2 e SPOT-5. O classificador supervisionado adotado requer de imagem segmentada na fase de coleta das áreas de treinamento. Sendo assim, julgou-se melhor dividir as abordagens: segmentação e classificação.

6.1 – SEGMENTAÇÃO DAS IMAGENS

Como já mencionado na subsubseção 5.3.4.2, a combinação das variáveis de índice de similaridade e tamanho mínimo de área foi realizada para cada imagem individualmente, buscando-se obter o melhor resultado para cada produto analisado. Convém informar que se trata de uma avaliação visual, passível de subjetividade por parte do analista. NA tentativa de minimizar qualquer tendenciosidade, deve-se ter bem definido qual o objetivo do procedimento no trabalho em questão.

Nessa pesquisa, priorizou-se o delineamento do uso em parcelas agrícolas com discriminação dos limites dos talhões, tomando-se como referência o reconhecimento de campo e interpretação visual das imagens.

A apresentação desses resultados será dividida por tipos de satélites; inicialmente são comentados os resultados obtidos nas imagens SPOT-5 e posteriormente os referentes ao QuickBird-2. Por último será efetuada a comparação entre os resultados de segmentação nas seguintes situações: imagens de mesma data com resolução espacial diferente; e imagens de datas diferentes com mesma resolução espacial. Para ilustração das imagens segmentadas foram selecionadas pequenas áreas da bacia, sendo apresentadas na escala aproximada de 1/10.000. A ilustração da segmentação nas imagens do SPOT-5 e do QuickBird-2 é apresentada para uma área de 1.117 m x 500 m.

6.1.1 – Imagens do SPOT-5

O procedimento de segmentação foi realizado nas imagens originais, uma multiespectral e duas pancromáticas, e, também, nas imagens obtidas por reamostragem. Foram geradas seis imagens rotuladas, correspondendo a cada produto, como apresentado a seguir.

- Imagem multiespectral, composta por quatro bandas, com resolução de 10 metros. Efetuou-se o processo de segmentação na banda original com maior variação tonal, a banda 2. Porém o melhor resultado obtido para essa banda, com limiares de 12 (similaridade) e 20 (área), não foi satisfatório, visto que não houve a delimitação de algumas áreas representativas, devido à semelhança da resposta espectral com feições da vizinhança. A partir de combinações de bandas, obteve-se melhora na segmentação a partir das bandas originais 1, 2 e 3, por meio dos limiares 10/20 (Figura 6.1).




Figura 6.1 – Imagem rotulada a partir das bandas 1, 2 e 3 com os limiares 10 para similaridade e 20 para área.

- Imagem pancromática, com resolução de 5 metros. De acordo com a identificação dos alvos por interpretação visual das imagens, obteve-se melhor delimitação para essa imagem ao se utilizar os limiares 6 para similaridade e 70 para área (Figura 6.2).




Figura 6.2 – Imagem rotulada a partir da banda pancromática de 5 m com os limiares 6 para similaridade e 70 para área.

- Imagem pancromática, resolução 2,5 m. Seguindo o mesmo critério utilizado nas outras imagens, constatou-se que para os limiares 8 para similaridade e 140 para área obteve-se o resultado de melhor aceitação (Figura 6.3).




Figura 6.3 – Imagem rotulada a partir da banda pancromática de 2,5 m com os limiares 8 para similaridade e 140 para área.

- Imagem pancromática reamostrada de 5 m para 10 m (5p10). O melhor delineamento para essa imagem foi alcançado com o índice de similaridade 6 e área mínima 20 (Figura 6.4).




Figura 6.4 – Imagem rotulada a partir da banda pancromática de 10 m obtida pela reamostragem da pan 5 m com os limiares 6 para similaridade e 20 para área.

- Imagem pancromática reamostrada de 2,5 m para 5 m (2,5p5). Utilizando-se para o limiar de similaridade 8 e limiar de área 70, conseguiu-se a melhor segmentação (Figura 6.5).




Figura 6.5 – Imagem rotulada a partir da banda pancromática de 5 m obtida pela reamostragem da pan 2,5 m com os limiares 8 para similaridade e 70 para área.

- Imagem pancromática reamostrada de 2,5 m para 10 m (2,5p10). O melhor resultado obtido nessa imagem foi para a combinação 8 e 20, respectivamente, similaridade e área (Figura 6.6).



Figura 6.6 – Imagem rotulada a partir da banda pancromática de 10 m obtida pela reamostragem da pan 2,5 m com os limiares 8 para similaridade e 20 para área.

6.1.2 – Imagens do QuickBird-2

A segmentação foi efetuada nas imagens originais, multiespectral e pancromática.

- Imagem multiespectral, contendo quatro bandas e com resolução espacial de 2,8 m. Os testes foram iniciados na banda 4 por esta apresentar maior variância. A tentativa inicial de limiares foi baseada no melhor resultado obtido na imagem pancromática 2,5 m do SPOT-5, limiares de 8/140 (similaridade/área). Partiu-se desse princípio devido à resolução espacial dessas imagens serem próximas. O melhor resultado de segmentação utilizando-se a banda 4 foi obtido com os limiares de 7/100. Ao realizar uma análise individual nas outras bandas, constatou-se que essa combinação de limiares também resultou na melhor segmentação. Porém, ao se estabelecer uma comparação entre o resultado final de cada banda, em termos quantitativos, observou-se que as segmentações feitas nas bandas 4 e 3 foram as que apresentaram maior número de delineamentos. Tal fato era esperado já que essas bandas são as que possuem maior contraste. A diferença entre elas foi bastante notória nas áreas com vegetação de grande porte (mata ciliar e eucaliptos). Para essas áreas, constatou-se uma visualização mais nítida na banda 4, inclusive sendo perceptível o sombreamento das árvores e um contraste notório entre aquela vegetação e sua sombra. No caso da banda 3, isso não ocorreu, pois há maior uniformidade do nível cinza que representa essas áreas. Devido a esse fator, a fragmentação nessas áreas apresentou-se excessiva

ao utilizar a banda 4, enquanto que para o resultado referente à banda 3, obteve-se polígonos melhor definidos. Por outro lado, na maior parte das áreas referentes aos talhões de horticultura, obteve-se melhor resultado na segmentação da banda 4, pois essas feições apresentaram bom contraste. Já no caso das áreas de fruticultura não se obteve delineamentos satisfatórios. A partir dessa abordagem, observa-se que em áreas caracterizadas por vários tipos de cobertura, a definição das bandas utilizadas na segmentação é muito específica ao que se pretende enfatizar, nem sempre a banda de maior variância ou a combinação das bandas de maior variância apresentará a segmentação mais adequada. Por exemplo, nesse caso, cujo produto tem alta resolução espacial, optou-se pela exclusão da banda 4, dada a grande fragmentação nas áreas com vegetação de grande porte (mata ciliar e eucaliptos) considerando que esse fator interfere na coleta das amostras referentes a essas classes na etapa de treinamento, tornando-a mais trabalhosa. Ademais, quanto às áreas agricultáveis, somente nas referentes à horticultura verificou-se bom delineamento. Com isso, testou-se combinações de bandas e obteve-se a melhor segmentação ao utilizar em conjunto as bandas 1, 2 e 3, para os limiares de 7/100 (Figura 6.7).



Figura 6.7 – Imagem rotulada a partir das bandas 1, 2 e 3 com os limiares 7 para similaridade e 100 para área.

- Imagem pancromática com 0,7 metro de resolução espacial. No caso dessa imagem, não foi possível obter uma boa segmentação entre as áreas cultivadas, pois a imagem apresenta uma tonalidade uniforme, como se observa no histograma da imagem apresentado na figura 6.8. Mesmo estabelecendo um baixo valor de similaridade não se alcançou uma segmentação satisfatória. Porém, visualmente, foi possível fazer a identificação dos alvos, interpretação proporcionada pela altíssima resolução espacial da imagem, diferenciando-os por

tipos de texturas. A Figura 6.8 mostra a segmentação ao utilizar os limiares de 4/1600. Este foi o melhor resultado obtido, porém não se considera satisfatório.




Figura 6.8 – Imagem rotulada a partir da banda pancromática de 0,70 m com os limiares 4 para similaridade e 1600 para área, e histograma da imagem.

6.1.3 – Comparação entre as segmentações das imagens

Inicialmente, fez-se uma comparação entre as imagens com diferentes resoluções espaciais e de mesma data. Efetuou-se a análise em dois conjuntos de imagens, uma do SPOT-5 e outra do QuickBird-2.

Ao segmentar imagens de uma dada área com resoluções espectral, temporal e radiométricas semelhantes, sendo o fator diferencial a resolução espacial dessas imagens, tem-se que dentre os limiares de segmentação, o limiar de área é o que apresentará maior influência no aparecimento de pequenos fragmentos.

Analisando-se a imagem pancromática do SPOT-5 com resolução de 2,5 m datada do dia 02 de maio de 2004, também reamostrada para as resoluções de 5 m e 10 m, observou-se que o melhor resultado obtido para a resolução de 10 m foi para os limiares de 8/20 (similaridade/área). Foi testada essa combinação para as outras duas imagens, verificando-se, como esperado, que nessa situação, ao manter-se o limiar de área, haveria um maior surgimento de pequenos fragmentos nas imagens com maior resolução espacial.

Entre as imagens pancromáticas em análise, obteve-se segmentações equivalentes para os seguintes limiares de similaridade/área: imagem original de 2,5 m, 8/140; imagem reamostrada para 5 m, 8/70; e imagem reamostrada para 10 m, 8/20. Buscando-se alcançar segmentações mais idênticas entre essas imagens, também variou-se o limiar de similaridade nas imagens, mas não ocorreram mudanças representativas na segmentação.

Confirma-se, assim, a maior influência do limiar de área para essa situação. A título de ilustração os resultados de segmentação mais próximos entre as imagens são apresentados na Figuras 6.9. Cada Figura ilustrada corresponde à dimensão: 425 m x 425 m.




Figura 6.9 – Segmentação das imagens: a) pan 2,5 m, limiars (8/140); b) pan 5 m (2,5p5), limiars (8/70) e; c) pan 10 m (2,5p10), limiars (8/20).

No que se refere à análise entre as imagens do satélite QuickBird-2, multiespectral 2,8 m e pancromática 0,7 m, não foi possível fazer a comparação quanto à influência da resolução espacial na segmentação do produto QuickBird-2, pois não se obteve um resultado satisfatório nas segmentações realizadas na imagem pancromática.

A outra análise refere-se a um conjunto de imagens com mesma resolução espacial pertencentes a datas diferentes. Para essa avaliação foram escolhidas as imagens do SPOT-5 com 10 metros de resolução espacial: multiespectral (29/04/03) – imagem original, e duas pancromáticas, ambas reamostradas, uma pela pan 2,5 m (02/05/04) e a outra pela pan 5 m (20/06/03). Adotou-se para a comparação a melhor segmentação obtida para cada imagem, correspondente aos seguintes limiars de segmentação (similaridade/área): 10/20 para a imagem multiespectral a partir das bandas 1, 2 e 3; 6/20 para a imagem pancromática reamostrada pela pan 2,5 m; e 8/20 para a pancromática obtida pela reamostragem da pan 5 m. Verificou-se, visualmente, que esses resultados não foram muito parecidos (Figura 6.10). Por se tratar de uma bacia tipicamente rural, cuja característica principal é a dinamicidade na mudança de cobertura do solo devido ao seu uso intensivo, era de se esperar uma diferença considerável na segmentação, principalmente entre as imagens de 2004 e as de 2003. Cada figura ilustrada corresponde à dimensão: 520 m x 520 m




Figura 6.10 – Imagens rotuladas: a) multiespectral (10/20), b) pan 10 m reamostrada pela pan 5 m (6/20) e c) pan 10 m reamostrada pela pan 2,5 m (8/20).

No entanto, mesmo nas segmentações geradas pela imagem multiespectral (29/04/03) e pancromática (20/06/03), com defasagem temporal pequena, observou-se que algumas fragmentações obtidas na imagem multiespectral não foram delimitadas na pancromática devido ao baixo contraste dessa imagem (Figura 6.11). Cada ilustração corresponde a uma área de 700 m x 700 m.

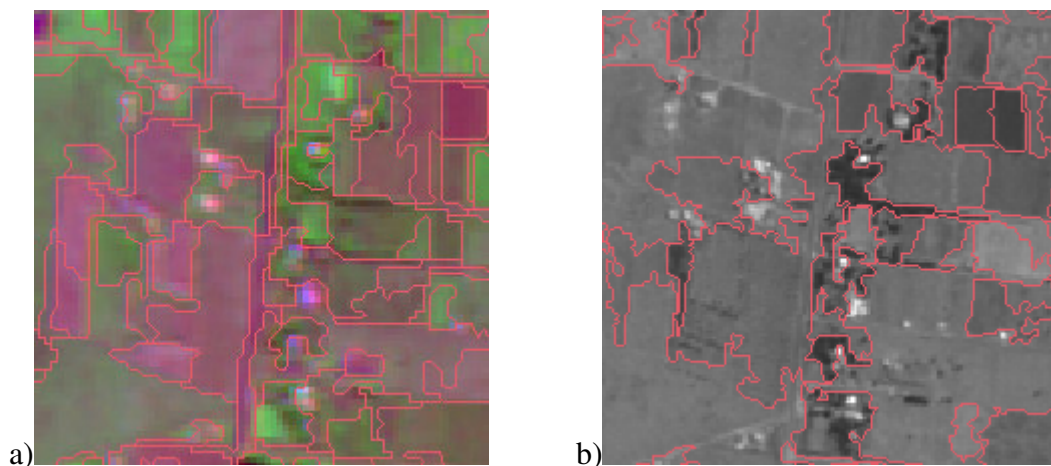


Figura 6.11 – Imagens do SPOT-5: a) Multiespectral com 10 m de resolução espacial (29/04/03), limiares 10/20 e b) Pancromática com 5 m de resolução espacial (20/06/03), limiares 6/70.

Enfocando as áreas agricultáveis, foi notório que em vários locais, devido à resposta espectral de talhões vizinhos ser muito semelhante, ocorreu a união desses em um único segmento, inclusive nas bandas espectrais de boa variação tonal.

Quanto ao tempo de processamento para a geração de uma imagem segmentada, como previsto, houve maior tempo de processamento nas seguintes situações: utilização de várias bandas espectrais; banda espectral de pouca variância; e imagem de maior resolução espacial.

6.2 – CLASSIFICAÇÃO DAS IMAGENS

Nesta seção são apresentados os resultados de classificação textural para as imagens multiespectrais e pancromáticas.

Cabe a ressalva de que o melhor resultado de classificação para cada imagem foi baseado na análise da respectiva matriz de confusão. Adotou-se, em consequência, o conjunto de medidas de textura que promoveu o maior desempenho médio na classificação das amostras de treinamento.

O desempenho médio refere-se à proporção das áreas das amostras corretamente classificadas, que por sua vez corresponde à razão entre a soma das áreas das amostras corretamente classificadas e a soma de todas as áreas das amostras de treinamento.

Aplicou-se o classificador em estudo nas imagens do SPOT-5 e do QuickBird-2, utilizando-se uma legenda única de modo a uniformizar as informações temáticas. Houve o cuidado de se escolher as mesmas localizações geográficas durante a coleta das áreas de treinamento, baseando-se no reconhecimento de campo e na imagem fundida. Buscou-se, assim, refinar o processo de classificação, a fim de proporcionar uma avaliação quanto à acurácia obtida nos mapeamentos temáticos gerados por cada imagem.

Adotou-se as seguintes classes temáticas: mata, reflorestamento, cerrado, campo limpo, campo cerrado, horticultura1, horticultura2, fruticultura, solo exposto e áreas construídas.

Apesar da identificação das feições correspondentes às classes estradas pavimentadas, estradas sem pavimentação e reservatórios, na classificação não se utilizou tais classes. A não inclusão foi atribuída a insatisfatória delimitação desses alvos. No classificador ClaTex, a extração das características texturais para cada classe é baseada nas suas amostras de treinamento. Assim sendo, ao selecionar amostras comprometidas pelo delineamento das suas bordas, é provável que ocorra o aumento de confusão entre classes, diminuindo o desempenho médio da classificação, visto que se inserem em amostras não representativas e não confiáveis. Efetuou-se uma classificação com a inclusão dessas classes para verificar o que ocorre na desempenho do classificador e o resultado é mostrado adiante.

No caso das estradas, apesar da identificação visual desses alvos, o problema de delineamento em alguns trechos foi causado pela similaridade espectral com a vizinhança. Em relação às áreas dos reservatórios de água, não se obteve o delineamento desse alvo em várias partes da imagem devido ao tamanho das áreas. Cabe lembrar que ao utilizar o algoritmo de segmentação crescimento por regiões, o analista define os limiares de similaridade e de área. O limiar de área refere-se à área mínima para o agrupamento dos pixels em regiões. Nesta pesquisa, o limiar de área foi baseado no tamanho dos talhões e, como a maioria dos reservatórios possui área inferior àquela, o delineamento desse tipo de alvo, de modo geral, ficou comprometido.

A seguir são apresentados os conjuntos de medidas de textura utilizados no resultado final da classificação referente a cada imagem. Para a seleção das medidas de textura, efetuou-se a classificação de cada imagem por dois tipos de procedimentos: seleção automática e seleção manual.

6.2.1 – Imagens multiespectrais

Em relação à imagem multiespectral do SPOT-5 com 10 m de resolução espacial, tem-se que por meio da função de seleção de medidas automáticas o melhor conjunto de medidas selecionadas foi: média vetor soma pela banda 2 (vermelho); e homogeneidade, correlação, média vetor soma e média vetor diferença pela banda 3 (infravermelho próximo). Obteve-se um desempenho médio de classificação de 86,57%. Efetuando-se a seleção de medidas manualmente, obteve-se o melhor resultado utilizando as seguintes medidas de textura: entropia, correlação, média vetor soma e entropia vetor soma extraídas a partir da banda 2 (vermelho); e média vetor soma a partir da banda 3 (infravermelho próximo). Em síntese, o maior desempenho médio de classificação, 94,61%, foi obtido com duas camadas e cinco medidas estatísticas.

No que se refere à imagem multiespectral do QuickBird-2 com 2,8 m de resolução espacial, efetuou-se o procedimento de classificação de modo análogo ao realizado na imagem multiespectral do SPOT-5. A partir da seleção automática das medidas, obteve-se um desempenho médio de 73,78%. As medidas utilizadas foram: banda 3 – média vetor soma e entropia vetor diferença; e banda 4 – entropia, média vetor soma, média vetor diferença, entropia vetor soma, dissimilaridade, entropia vetor diferença, correlação,

homogeneidade e chi-quadrado. Pela seleção manual, obteve-se o maior desempenho médio de classificação a partir do seguinte conjunto de medidas de textura: homogeneidade, dissimilaridade e média vetor soma, calculadas pela banda 3 (vermelho); e entropia, homogeneidade, média vetor soma e média vetor diferença determinadas pela banda 4 (infravermelho próximo). O desempenho médio de classificação foi de 97,43%.

A título de verificação da afirmação feita com relação ao possível problema de confusão entre classes ao se acrescentar as classes temáticas – estradas pavimentadas, estrada sem pavimentação e reservatórios – efetuou-se uma nova classificação na imagem multiespectral do Quickbird-2, com base nos mesmos parâmetros que resultaram no melhor desempenho médio (97,43%), incluindo-se as três classes acima citadas. Houve um decaimento do desempenho médio da classificação, resultando em 82,85% de desempenho. Isto comprova que a inserção de classes que não possuam amostras confiáveis pode ser um fator a comprometer a acurácia da classificação da imagem.

6.2.2 – Imagens pancromáticas

A princípio, efetuou-se a classificação na imagem pan 2,5 m, com o propósito de se avaliar o desempenho do classificador em imagens pancromáticas de muito alta resolução espacial.

Devido à dificuldade em se identificar algumas feições decorrentes da semelhança tonal, utilizou-se a composição colorida da imagem fusionada como referência durante a coleta das áreas de treinamento.

Vale a ressalva de que a adoção da melhor classificação foi baseada apenas na matriz de confusão, sendo esta correspondente às amostras de treinamento.

No que tange à imagem pancromática do SPOT-5 com 2,5 m de resolução espacial, o resultado obtido pelo desempenho médio de classificação utilizando-se as medidas de texturas selecionadas automaticamente (média vetor soma, correlação, energia vetor diferença, entropia vetor diferença e chi-quadrado) foi de 60,49%. Pela escolha manual das medidas de textura, obteve-se 82,57% de desempenho médio, utilizando-se as seguintes

medidas texturais: chi-quadrado, média vetor soma, entropia vetor soma e energia vetor diferença.

Quanto à imagem pancromática do SPOT-5 de 5 m de resolução espacial, pela seleção automática do conjunto de medidas de textura, a partir das medidas de média vetor soma, dissimilaridade, energia vetor diferença, entropia vetor diferença, entropia e correlação, alcançou-se um desempenho médio de 78,11%. Pelo procedimento manual de escolha das medidas, o desempenho médio foi de 82,57% para o seguinte conjunto de medidas: entropia, dissimilaridade, correlação, chi-quadrado, média vetor soma, variância vetor soma, entropia vetor soma, entropia vetor diferença e cluster prominence.

Com o propósito de avaliar o comportamento da acurácia da classificação atribuído a diferentes resoluções espaciais, efetuou-se a classificação nas imagens pancromáticas de 5 m e 10 m, obtidas pela reamostragem da imagem pan 2,5 m do SPOT-5. Sabendo-se que o único parâmetro alterado foi a resolução espacial, enfatizando que a finalidade principal foi verificar a influência desse parâmetro na acurácia da classificação.

O procedimento de classificação das imagens reamostradas foi análogo ao da imagem pan 2,5 m, selecionando-se as medidas texturais utilizadas no resultado final da pan 2,5 m. Os desempenhos médios obtidos foram: 72,90% para a imagem pancromática de 5 m e 64,62% para a imagem pancromática de 10 m.

Pelos resultados obtidos, verifica-se, que o melhor conjunto de medidas para uma imagem é específico a ela, confirmando-se os comentários de Ruiz *et al.* (2002) e Greenspan *et al.* (1994).

Comparando-se os resultados obtidos pela seleção automáticas das medidas de textura e pela seleção manual das medidas de textura, observa-se que o critério utilizado pelo algoritmo para seleção do conjunto de medidas que possam melhor discriminar os alvos de interesse, procedimento elaborado com o intuito de minimizar o tempo computacional, não necessariamente resultará no maior desempenho médio da classificação.

As medidas selecionadas pelo fator discriminante entre duas classes, para cada imagem analisada, são apresentadas no Apêndice D.

De posse dos resultados das imagens classificadas, realizou-se as seguintes análises:

- Análise quantitativa nas classificações das imagens multiespectrais;
- Análise da influência da resolução espacial no desempenho médio do algoritmo;
- Avaliação qualitativa entre os mapas temáticos gerados e a verdade terrestre;
- Comparação entre as classificações dos diferentes produtos para uma área amostral buscando identificar detalhadamente a exatidão proporcionada por cada produto no mapeamento das áreas da cena.

6.2.3 – Análise quantitativa nas classificações das imagens multiespectrais

Utilizou-se o termo análise quantitativa ao procedimento de análise da acurácia da classificação com base, apenas, na matriz de confusão.

Para a imagem multiespectral do SPOT-5 com 10 metros de resolução espacial, a matriz de confusão com as percentagens de classificação das 10 classes, o desempenho médio, a abstenção e a confusão média são exibidos na Tabela 6.1.

Tabela 6.1– Matriz de classificação referente à imagem multiespectral do SPOT-5 (valores em %).

Classes	1	2	3	4	5	6	7	8	9	10
1	98,78						1,22			
2		100								
3			72,51		27,49					
4				91,25		8,75				
5					100					
6						100				
7	13,74				0,51		85,75			
8								100		
9				0,65				11,58	87,77	
10						16,75				83,25
Legenda:										
1 – Reflorestamento			3 – Fruticultura		5 - Horticultura 2		7 - Mata		9 - Campo cerrado	
2 - Cerrado		4 - Horticultura 1		6 - Solo Exposto		8 - Campo limpo		10 - A.Construídas		
Desempenho médio: 94,61			Abstenção média: 0,0			Confusão média: 5,39				

Como o classificador ClaTex não possui uma ferramenta de limiar de aceitação, os alvos correspondentes às classes não utilizadas (estradas pavimentadas, estradas sem pavimentação e reservatórios) serão classificadas como outras classes. Por esse motivo não haverá áreas não classificadas, sendo o valor de abstenção média igual a 0%.

Os valores da diagonal principal (em destaque) referem-se à porcentagem das amostras de cada classe corretamente classificadas.

Por meio da matriz de confusão apresentada na Tabela 6.1, observa-se que os maiores percentuais de confusão ocorreram entre as áreas amostrais correspondentes às classes: fruticultura e horticultura 2; horticultura 1 e solo exposto; campo cerrado e campo limpo; mata e reflorestamento; e áreas construídas e solo exposto.

Verifica-se que a confusão gerada entre as classes fruticultura e horticultura 2 pode ser atribuída à semelhança de uniformidade textural apresentada por essas áreas na imagem original, característica que pode ser atribuída à resolução espacial dessa imagem. No caso de uma imagem multiespectral de melhor resolução espacial, provavelmente a confusão seria menor em decorrência da melhor diferenciação textural entre as duas classes citadas.

Um outro fator que pode ter contribuído para a confusão de algumas classes refere-se à coleta de amostras uniformes. Como a etapa de treinamento é efetuada em polígonos definidos durante a segmentação, o ideal seria que se obtivesse boas delimitações para todos os alvos de interesse, algo difícil de acontecer dada a grande diversidade espacial da área estudada. No entanto, tal procedimento fica um pouco comprometido quando se têm comportamentos espectrais semelhantes, como é o caso da cena em estudo, visto que o agrupamento de regiões para a formação dos polígonos também está vinculado à resposta espectral das feições.

A seguir são apresentados alguns tipos de confusão de classes detectados no mapa temático, gerado a partir da imagem multiespectral do SPOT-5 (Figura 6.12). As elipses de linha contínua destacam confusões em amostras de treinamento e as de linha tracejada áreas erroneamente classificadas, devido à fragmentação da região de um mesmo alvo em polígonos menores, detectadas pela análise visual.

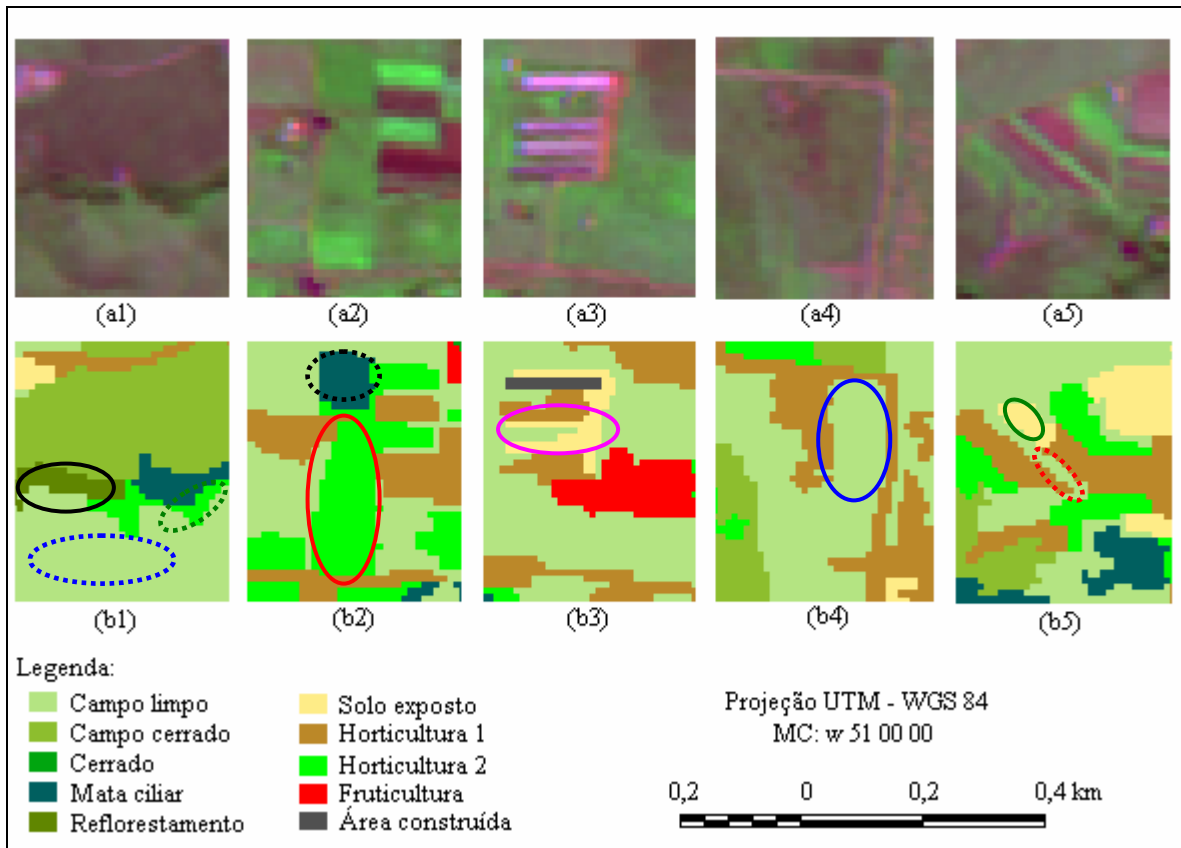


Figura 6.12 – Amostras da imagem multiespectral do SPOT-5 (a1 a a5) e respectivas amostras do mapa temático (b1 a b5).

No que se refere às elipses contínuas têm-se: em preto mata ciliar classificada como reflorestamento; em vermelho, fruticultura classificada como horticultura 2; em rosa, áreas construídas classificadas como solo exposto; em azul campo cerrado classificada como campo limpo; e em verde horticultura 1 classificada como solo exposto.

Por uma comparação visual do mapa temático gerado com a interpretação da imagem, auxiliada pelo reconhecimento de campo, verificou-se que também houve erros de classificação fora das amostras de treinamento, destacadas na Figura 6.12 por elipses tracejadas: em azul, campo cerrado classificada como campo limpo; em verde, mata como horticultura2; em preto, fruticultura como mata; em vermelho, horticultura 2 como campo limpo, entre outros.

Para a imagem multiespectral do QuickBird-2, de acordo com a matriz de confusão, o desempenho médio de classificação foi de 97,43%. A Tabela 6.2 apresenta a matriz de confusão referente às áreas de treinamento coletadas a partir da imagem rotulada gerada pelas bandas 1, 2 e 3 com limiares de 7/100 (similaridade/área).

Analisando-se os resultados apresentados na matriz de confusão (Tabela 6.2), verifica-se que os valores da diagonal principal, que representam a acurácia obtida em cada classe, são acima de 94%.

Tabela 6.2 – Matriz de classificação a partir da imagem multiespectral do QuickBird-2. (valores em %)

Classes	1	2	3	4	5	6	7	8	9	10
1	100									
2		100								
3			97,13		2,87					
4				99,31	0,23					0,46
5					100					
6						100				
7			0,64				99,36			
8				1,58	0,20			98,22		
9				3,38				2,47	94,15	
10										100
Legenda:										
1 – Reflorestamento 3 – Fruticultura 5 - Horticultura 2 7 - Mata 9 - Campo cerrado										
2 - Cerrado 4 - Horticultura 1 6 - Solo Exposto 8 - Campo limpo 10 - A.Construídas										
Desempenho médio: 97,43			Abstenção média: 0,0				Confusão média: 2,57			

Pelos resultados obtidos nas classificações das imagens multiespectrais do SPOT-5 e do QuickBird-2, nota-se que a questão dos fatores interferentes na confusão entre classes é muito específico para a imagem.

Uma pequena confusão pode ser causada por vários fatores, dentre eles, problemas de delimitação dos alvos, similaridade espectral das classes nas bandas espectrais, sombreamento e arranjo espacial dos alvos na superfície.

A seguir são comentados alguns problemas verificados na classificação, baseando-se nos resultados da matriz de confusão.

Com relação à confusão ocorrida entre algumas amostras de mata, classificadas como fruticultura, na imagem do QuickBird-2 (Figura 6.13 – elipse branca), observa-se que apesar da distinção textural promovida pela muito alta resolução espacial, houve confusão possivelmente atribuída à semelhança espectral destas classes na banda 4, uma das bandas utilizadas na classificação.

Outros tipos de confusão ocorreram devido ao pequeno tamanho dos segmentos ou comprometimento de delimitação de borda das amostras entre as classes, como se observa na Figura 6.13: campo limpo como horticultura 2 (elipse verde), campo limpo como horticultura 1 (elipse vermelha) e campo cerrado como horticultura 1 (elipse rosa).

Em se tratando das classes fruticultura e horticultura 2, tem-se, pela interpretação visual, que esta se apresentou com um efeito de textura mais lisa e aquela com um de textura mais rugosa atribuída a identificação dos seus portes e distribuição espacial, dada a muito alta resolução espacial da imagem. A distinção textural entre essas feições, apresentadas na imagem multiespectral do QuickBird-2, contribuiu para uma menor confusão entre as amostras de treinamento quando comparadas ao resultado referente à imagem do SPOT-5, de menor resolução espacial. A título de ilustração, na Figura 6.13 está identificada por uma elipse preta, uma área de fruticultura classificada como horticultura 2.

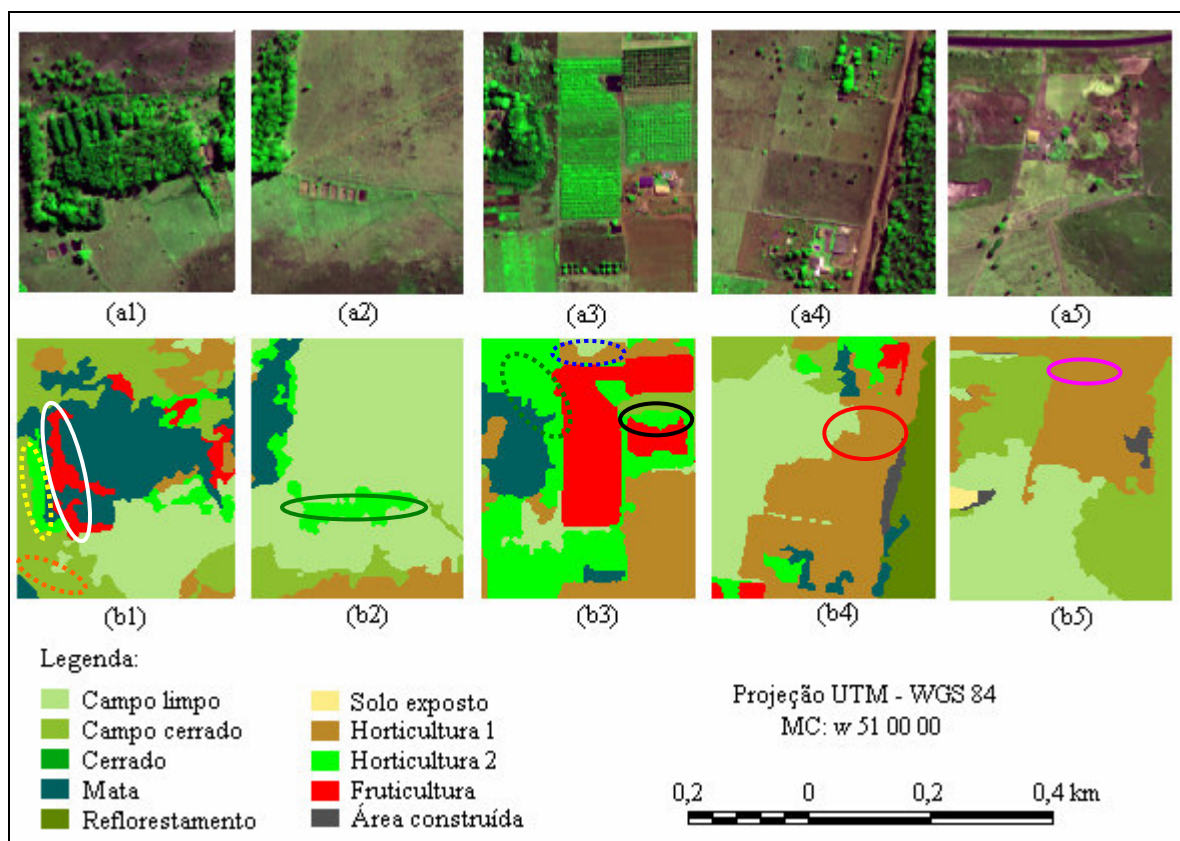


Figura 6.13 – Amostras da imagem multiespectral do QuickBird-2 (a1 a a5) e respectivas amostras do mapa temático (b1 a b5).

Além da ocorrência dos problemas de confusão entre amostras, identificadas por elipses contínuas na Figura 6.13, também se verificou, pela análise visual, que ocorreram erros nas classificações de outras áreas não utilizadas para o cálculo da matriz de confusão. A título

de ilustração estão destacados na Figura 6.13 por elipses tracejadas alguns tipos de problemas de classificação que ocorreram: mata ciliar como horticultura 2 (amarelo), campo limpo como campo cerrado (laranja), campo cerrado como horticultura 2 (verde), campo limpo com horticultura 1 (azul).

Cabe lembrar que a imagem multiespectral do QuickBird-2 corresponde ao período crítico de estiagem e a do SPOT-5 ao início da estiagem, ainda com o predomínio de uma paisagem de período chuvoso. Essa característica de mudança visual da paisagem bem perceptível é típica das regiões do cerrado por contemplarem duas estações bem distintas. Esse é um motivo para que a classificação de uma mesma área em imagens de datas diferentes seja passível de confusão, pois a paisagem de um alvo em uma determinada época do ano muitas vezes se confunde com a de outro alvo, como é o caso do campo cerrado e campo limpo, onde suas paisagens apresentam-se muito parecidas na estação de estiagem.

Aplicando-se a comparação da matriz de confusão das classificações em questão, verifica-se que para todas as classes da imagem QuickBird-2 houve um ganho na acurácia em relação à imagem SPOT-5, exceto para a classe campo limpo, na qual o desempenho caiu 1,78%. Embasando-se nesses resultados, pode-se afirmar que nas imagens multiespectrais, a melhora da resolução espacial contribuiu para o aumento da acurácia das classes, dado que a variabilidade de texturas foi melhor perceptível na interpretação visual da imagem do QuickBird-2. Destaca-se que análise refere-se somente às amostras de treinamento.

Em relação às imagens pancromáticas, como não se obteve resultados desejáveis no que se refere ao desempenho médio das classificações, acima de 90%, optou-se em não realizar este tipo de análise.

Ainda referindo-se às imagens pancromáticas, devido à banda pancromática abranger uma larga faixa de comprimento de onda, envolvendo os comprimentos de onda das bandas verde, vermelho e parcialmente a infravermelho próximo, ficou notória a limitação na diferenciação espectral entre diferentes feições, sendo esta a principal causa na confusão das amostras.

6.2.4 – Análise da influência da resolução espacial

Apesar de se ter conhecimento que a degradação espacial da imagem causa perda de informação de textura, efetuou-se esse procedimento nas imagens pancromáticas com o intento de analisar a influência da resolução espacial das imagens para uma mesma condição de aquisição.

Ao comparar os resultados referentes aos desempenhos médios de classificação obtidos para as imagens pancromáticas do SPOT-5 de 2,5 m de resolução espacial, também reamostrada para 5 m e 10 m: 82,57%, 72,90%, 64,62%, respectivamente, verifica-se, nesse caso, que houve um decaimento em torno de 10%.

A partir dos valores da diagonal principal da matriz de confusão de cada imagem foram gerados gráficos para fins comparativos de acurácia das amostras das classes em diferentes resoluções espaciais (Figura 6.14).

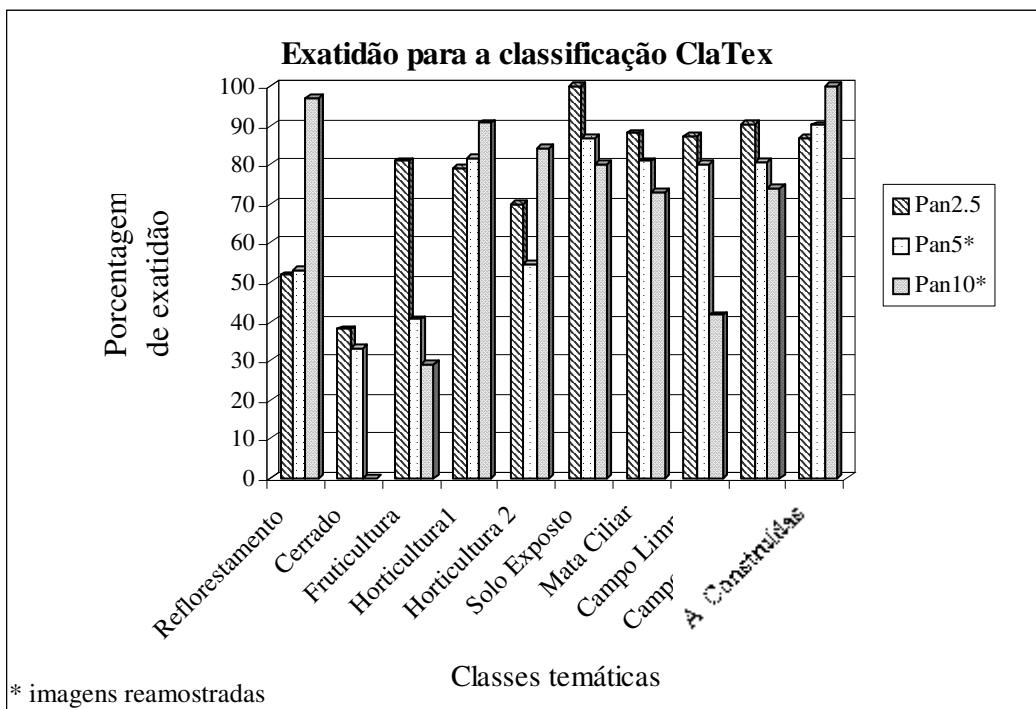


Figura 6.14 – Gráficos gerados a partir das matrizes de confusão referentes às imagens pancromáticas do SPOT-5 de 2,5 m de resolução espacial, também reamostrada para 5 m e 10 m

De acordo com a Figura 6.14 a degradação na resolução espacial provocou o decaimento da acurácia das classes: cerrado, fruticultura, solo exposto, mata ciliar, campo limpo, campo cerrado. Entretanto, parecendo contraditório, para as classes reflorestamento, horticultura 1 e áreas construídas, ocorreu o inverso, aumento da acurácia das classes citadas ao degradar a imagem. Tal fato pode ter acontecido devido à uniformização tonal dos pixels nessas áreas amostrais, desaparecendo a heterogeneidade nas amostras, e talvez ao fato de que essa uniformização, para estas classes especificamente, cria faixas de níveis de cinza diferenciadas em relação às demais classes. Cabe lembrar que, apesar da seleção criteriosa das amostras, tendo sido coletadas nos mesmos locais nas respectivas imagens, os contornos das amostras (efeito de borda da vizinhança) não eram idênticos, apenas visualmente parecidos, pois se trata de uma delimitação automática definida por limiares.

De acordo com os resultados obtidos, é válido comentar, também, que quanto melhor a resolução espacial maior a discriminação de outros objetos intrínsecos na amostra. Como se trata de uma imagem com limitação espectral, composta por uma banda, é possível que ocorra a diminuição de confusão entre duas classes quanto melhor seja a resolução espacial. Por outro lado, dependendo dos tipos de alvos que compõem a imagem, essa melhora poderá causar confusão entre outras classes que antes não apresentavam semelhança na textura.

6.2.5 – Análise entre os mapas temáticos gerados e a verdade terrestre

Esta análise pode ser dividida em duas etapas: cálculo do erro relativo referente à medição de área de cada classe temática obtida com o objetivo de verificar os problemas inerentes ao método de classificação utilizado, bem como ao tipo de produto utilizado; e, comparação visual entre o mapa temático obtido por meio da classificação textural e a verdade terrestre, buscando averiguar áreas classificadas erroneamente.

É válido lembrar que alguns erros, em algumas classes, já são esperados, pois na medição da verdade terrestre estão inclusas as classes reservatórios, estradas pavimentadas e estradas sem pavimentação. Na classificação das imagens, essas áreas foram associadas a uma das classes temáticas em questão, a partir da regra de decisão distância de Mahalanobis.

6.2.5.1 – Imagem multiespectral do QuickBird-2 com resolução espacial de 2,8m.

Na Tabela 6.3, são mostrados os erros relativos às diferenças de áreas de cada classe calculadas pelo classificador para a imagem multiespectral do QuickBird-2.

Tabela 6.3 – Áreas dos temas mapeados pela interpretação visual e pelo classificador ClaTex para a imagem multiespectral do QuickBird-2 e o erro relativo das áreas das classes temáticas geradas pelo classificador.

Classes temáticas	Cálculo das áreas				Erro relativo (%)
	Verdade terrestre		Classificação		
	km ²	%	km ²	%	
Mata	1,418267	8,65	1,118768	6,82	-21,12
Cerrado	0,24643	1,50	0,219489	1,34	-10,93
Campo limpo	6,503224	39,67	4,737508	28,90	-27,15
Campo cerrado	3,939784	24,03	2,698551	16,46	-31,51
Horticultura 1	1,739091	10,61	5,038732	30,73	189,73
Horticultura 2	0,866751	5,29	1,415488	8,63	63,31
Fruticultura	0,527595	3,22	0,65504	4,00	24,16
Solo exposto	0,363012	2,21	0,049118	0,30	-86,47
Áreas construídas	0,068757	0,42	0,125134	0,76	81,99
Reservatórios de água	0,026851	0,16	-	-	-
Reflorestamento	0,485127	2,96	0,337206	2,06	-30,49
Estradas pavimentadas	0,109289	0,67	-	-	-
Estradas sem pavimentação	0,100856	0,62	-	-	-
Total	16,395034	100	16,395034	100	

Nota: o sinal negativo representa que a medição de área foi subestimada.

Com base nos erros obtidos, observa-se que os maiores problemas de classificação ocorreram para as classes: horticultura1, áreas construídas (classes superestimadas); e solo exposto (classe subestimada).

Pela análise visual observa-se que áreas pertencentes a outras classes foram classificadas como horticultura 1, predominando esse tipo de confusão em áreas de campo cerrado e solo exposto. Tal problema superestimou a área de horticultura 1 presente na sub-bacia. A causa principal foi a errônea delimitação das regiões desses alvos, que por sua vez pode ter sido causada pela semelhança espectral entre essas vizinhanças.

Cabe lembrar que não se utilizou as classes estradas e reservatórios, sendo o principal fator o problema de delineamento para a coleta das amostras. Dessa forma, o classificador associou tais áreas a uma das classes em estudo, visto que o classificador Clatex não possui uma ferramenta que considere limiar de aceitação. Dentro desse contexto, verifica-se que as áreas da sub-bacia correspondentes às estradas pavimentadas e estradas sem pavimentação foram classificadas predominantemente como horticultura1.

A formação de pequenos polígonos, caracterizando uma imagem rotulada bastante segmentada em algumas regiões desta, comprometeu a classificação dessas pequenas áreas.

Ressalva-se que, para esse classificador, a classificação de um segmento é feita a partir de uma comparação estatística entre a informação textural do segmento e a de cada classe em questão, sendo esse segmento atribuído à classe a que estiver mais próximo estatisticamente.

A imagem classificada referente à imagem multiespectral do QuickBird-2 é apresentada na Figura 6.15.

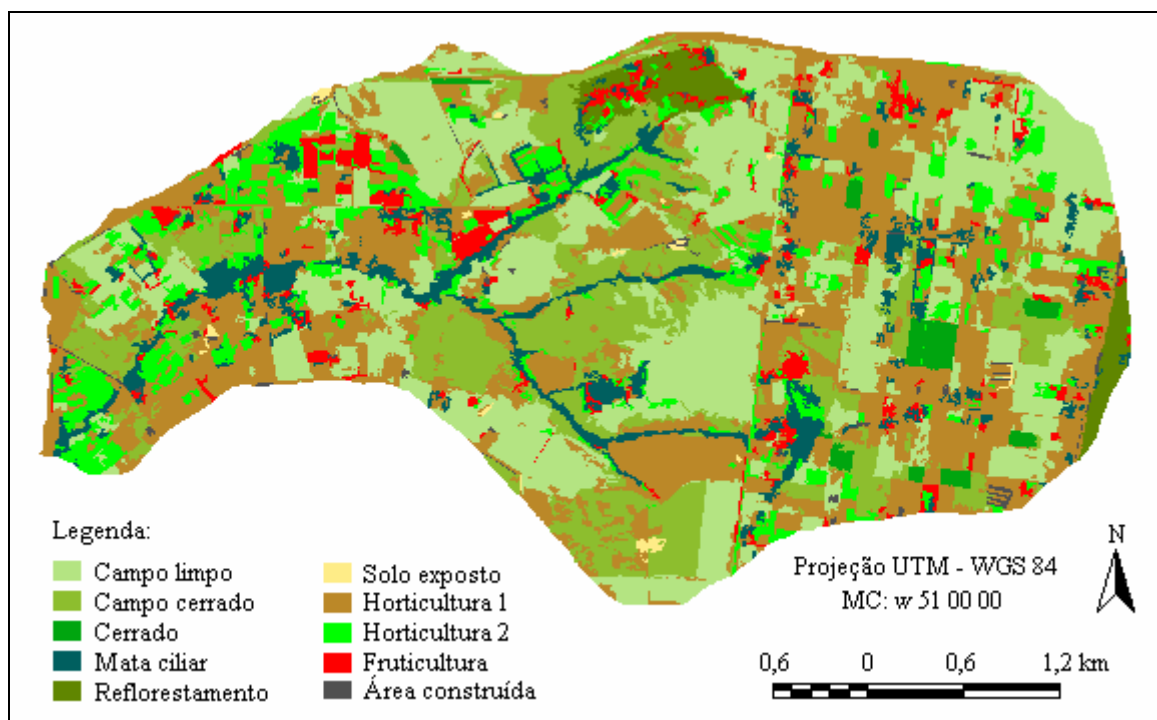


Figura 6.15 – Classificação da imagem multiespectral do QuickBird-2 com 2,8 m de resolução espacial.

6.2.5.2 – Imagem multiespectral do SPOT-5 com resolução espacial de 10m

Na Tabela 6.4, são mostrados os erros relativos com relação às diferenças de áreas de cada classe calculadas pelo classificador para a imagem multiespectral do SPOT-5.

A partir dos valores apresentados na Tabela 6.4, observa-se que a maior diferença de cálculo de área ocorreu para a classe horticultura 2, superestimando-a em 182,27%. Comparando-se visualmente a imagem fusionada utilizada para a interpretação visual e a imagem classificada, verifica-se que algumas áreas referentes às classes campo limpo e campo cerrado foram classificadas como horticultura 2. O problema ocorreu principalmente pela similaridade espectral das regiões correspondentes a essas feições nas bandas espectrais utilizadas para a extração textural. Como a imagem em questão possui baixa resolução espacial, e, refere-se ao final do período chuvoso, as coberturas vegetais de algumas feições quando comparada às demais imagens apresentaram-se muito semelhantes em suas reflectâncias.

Tabela 6.4 – Áreas dos temas mapeados pela interpretação visual e pelo classificador ClaTex para a imagem multiespectral do SPOT-5 e o erro relativo das áreas das classes temáticas geradas pelo classificador.

Classes temáticas	Cálculo das áreas				Erro relativo (%)
	Verdade terrestre		Classificação		
	km ²	%	km ²	%	
Mata	1,418267	8,65	1,035000	6,31	-27,02
Cerrado	0,24643	1,50	0,176800	1,08	-28,26
Campo limpo	6,503224	39,67	6,011360	36,67	-7,56
Campo cerrado	3,939784	24,03	2,151466	13,12	-45,39
Horticultura 1	1,739091	10,61	3,345866	20,41	92,39
Horticultura 2	0,866751	5,29	2,446600	14,92	182,27
Fruticultura	0,527595	3,22	0,211170	1,29	-59,97
Solo exposto	0,363012	2,21	0,548793	3,35	51,18
Áreas construídas	0,068757	0,42	0,030293	0,18	-55,94
Reservatórios de água	0,026851	0,16	-	-	-
Reflorestamento	0,485127	2,96	0,437686	2,67	-9,78
Estradas pavimentadas	0,109289	0,67	-	-	-
Estradas sem pavimentação	0,100856	0,62	-	-	-
Total	16,395034	100	16,395034	100	

A imagem classificada referente à imagem multiespectral do SPOT-5 é apresentada na Figura 6.16.

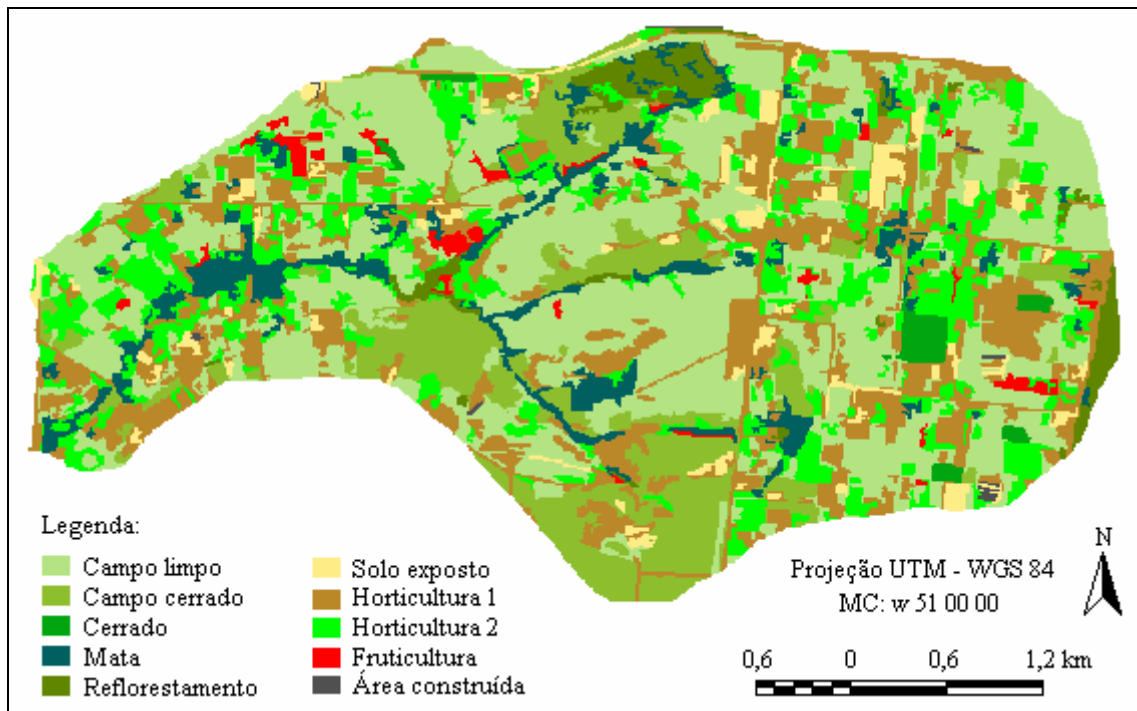


Figura 6.16 – Classificação da imagem multiespectral do SPOT-5 com 10 m de resolução espacial.

Pela análise visual verifica-se que as estradas sem pavimentação foram classificadas como horticultura 1 e também algumas regiões de estradas pavimentadas. Destaca-se também algumas regiões de campo cerrado classificadas como horticultura 1. Nesse caso, vários fatores devem ser levados em consideração no que se refere a essa diferença de valores, como: o erro devido à associação das classes estradas a esta classe; as medições são baseadas em datas diferentes, dessa forma os locais de horticultura 1 podem não corresponder a esta classe, mas provavelmente a horticultura 2, dado curto período vegetativo do cultivo.

Com relação à superestimação da classe solo exposto, observa-se que algumas áreas de estradas pavimentadas e sem pavimentação foram classificadas como essa classe. Também houve problemas de classificação em áreas correspondente à fruticultura, áreas de plantio recente, o que fez predominar a reflectância do solo.

Por consequência da superestimação de algumas classes, ocorreu a subestimação de outras, como campo cerrado, campo limpo, fruticultura, etc.

No caso de áreas correspondentes à classe mata, ocorreram confusões principalmente com a classe de reflorestamento. Ambas as classes caracterizam-se por vegetação de grande porte. O problema pode ter ocorrido em tais polígonos por estes apresentarem características texturais mais próximas à da classe reflorestamento.

6.2.5.3 – Imagem pancromática do SPOT-5 com resolução espacial de 2,5m

Na Tabela 6.5, são mostrados os erros relativos às diferenças de áreas de cada classe calculadas pelo classificador para a imagem pancromática de 2,5m do SPOT-5.

Tabela 6.5 – Áreas dos temas mapeados pela interpretação visual e pelo classificador ClaTex para a imagem pancromática de 2,5 m do SPOT-5 e o erro relativo das áreas das classes temáticas geradas pelo classificador.

Classes temáticas	Cálculo das áreas				Erro relativo (%)
	Verdade terrestre		Classificação		
	km ²	%	km ²	%	
Mata	1,418267	8,65	1,157525	7,06	-18,38
Cerrado	0,24643	1,50	0,132581	0,81	-46,20
Campo limpo	6,503224	39,67	2,216021	13,52	-65,92
Campo cerrado	3,939784	24,03	4,4472102	27,13	12,88
Horticultura 1	1,739091	10,61	0,493681	3,01	-71,61
Horticultura 2	0,866751	5,29	1,588915	9,69	83,32
Fruticultura	0,527595	3,22	5,0742974	30,95	861,78
Solo exposto	0,363012	2,21	0,702619	4,29	93,55
Áreas construídas	0,068757	0,42	0,015113	0,09	-78,02
Reservatórios de água	0,026851	0,16	-	-	-
Reflorestamento	0,485127	2,96	0,5670724	3,46	16,89
Estradas pavimentadas	0,109289	0,67	-	-	-
Estradas sem pavimentação	0,100856	0,62	-	-	-
Total	16,395034	100	16,395034	100	

Comparando-se às tabelas anteriores, verifica-se que o percentual de desempenho médio de classificação interfere diretamente na classificação como um todo. Quanto menor o desempenho médio de classificação maior a perda de confiabilidade na qualidade da classificação.

Analisando-se os dados apresentados na Tabela 6.5, observa-se um maior erro na classificação da classe fruticultura, tendo sido superestimada. As maiores confusões dessa classe ocorreram em áreas de campo limpo, mata e horticultura 1.

No caso das áreas correspondentes às classes estradas sem pavimentação e estradas pavimentadas, estas foram classificadas, na maior parte, como fruticultura e em menor parte como solo exposto.

A imagem classificada referente à imagem pancromática do SPOT-5 de 2,5 m de resolução espacial é apresentada na Figura 6.17.

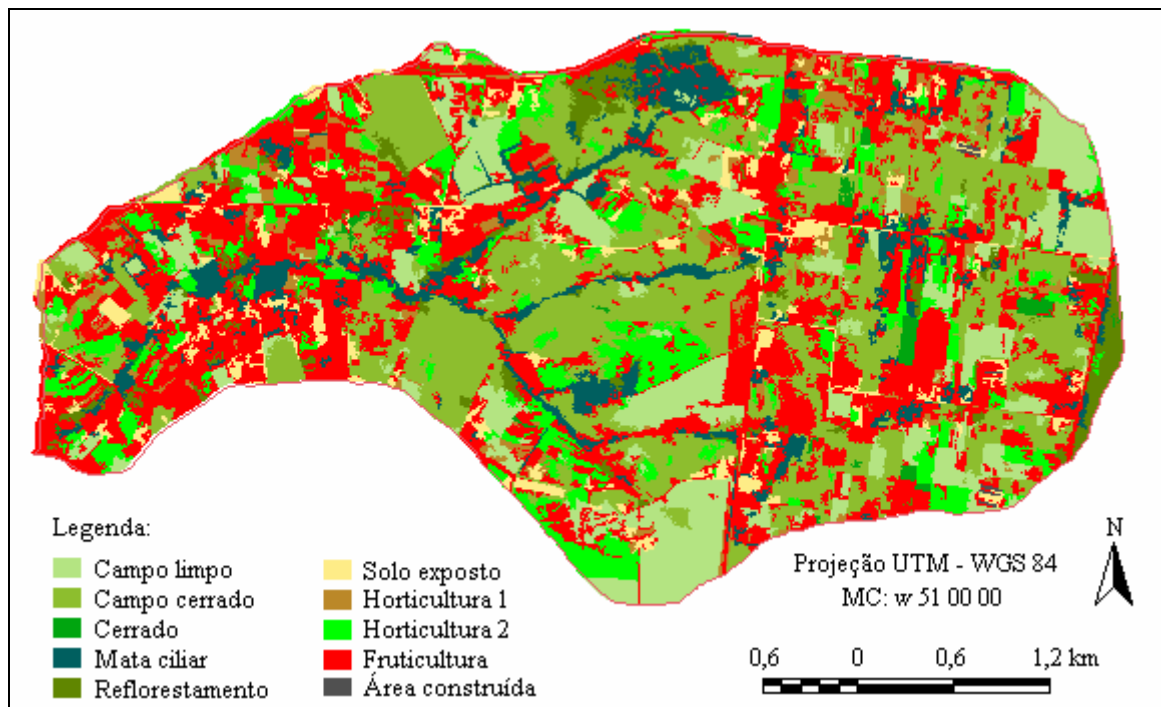


Figura 6.17 – Classificação da imagem pancromática do SPOT-5 com 2,5 m de resolução espacial.

6.2.5.4 – Imagem pancromática do SPOT-5 com resolução espacial de 5 m obtida pela reamostragem da imagem pan 2,5 m.

A seguir (Tabela 6.6) são apresentados os valores de cálculo de áreas do mapa temático gerado para imagem em questão e o erro relativo para cada classe.

Tabela 6.6 – Áreas dos temas mapeados pela interpretação visual e pelo classificador ClaTex para a imagem pancromática do SPOT-5 de 5 m reamostrada pela pan 2,5 m e o erro relativo das áreas das classes temáticas geradas pelo classificador.

Classes temáticas	Cálculo das áreas				Erro relativo (%)
	Verdade terrestre		Classificação		
	km ²	%	km ²	%	
Mata	1,418267	8,65	1,2914042	7,88	-8,94
Cerrado	0,24643	1,50	0,058225	0,36	-76,37
Campo limpo	6,503224	39,67	2,240196	13,66	-65,55
Campo cerrado	3,939784	24,03	5,2505376	32,03	33,27
Horticultura 1	1,739091	10,61	1,3153334	8,02	-24,37
Horticultura 2	0,866751	5,29	3,5298834	21,53	307,25
Fruticultura	0,527595	3,22	2,168671	13,23	311,05
Solo exposto	0,363012	2,21	0,2061	1,26	-43,23
Áreas construídas	0,068757	0,42	0,018475	0,11	-73,13
Reservatórios de água	0,026851	0,16	-	-	-
Reflorestamento	0,485127	2,96	0,3162084	1,93	-34,82
Estradas pavimentadas	0,109289	0,67	-	-	-
Estradas sem pavimentação	0,100856	0,62	-	-	-
Total	16,395034	100	16,395034	100	

Pelos valores apresentados na Tabela 6.6, observa-se significativas diferenças de áreas para as classes horticultura 2 e fruticultura. Os erros ocorreram, principalmente, nas áreas referentes às classes mata e campo cerrado, que foram classificadas erroneamente como fruticultura; e nas de campo limpo, campo limpo e cerrado, classificadas como horticultura 2.

A classificação, em um âmbito geral, não é confiável, pois a similaridade espectral entre as diferentes coberturas vegetais, ocasionado pela extração de informação de uma única banda de larga faixa espectral gerou dois tipos de problemas: um de delineamento dos polígonos e outro de semelhança textural entre diferentes alvos. Ademais, a interpretação visual em imagens pancromáticas, nessa área em estudo, ficou prejudicada, tornando difícil a identificação dos alvos.

A imagem classificada referente à imagem pancromática do SPOT-5 de 5m de resolução espacial reamostrada pela pan 2,5 é apresentada na Figura 6.18.

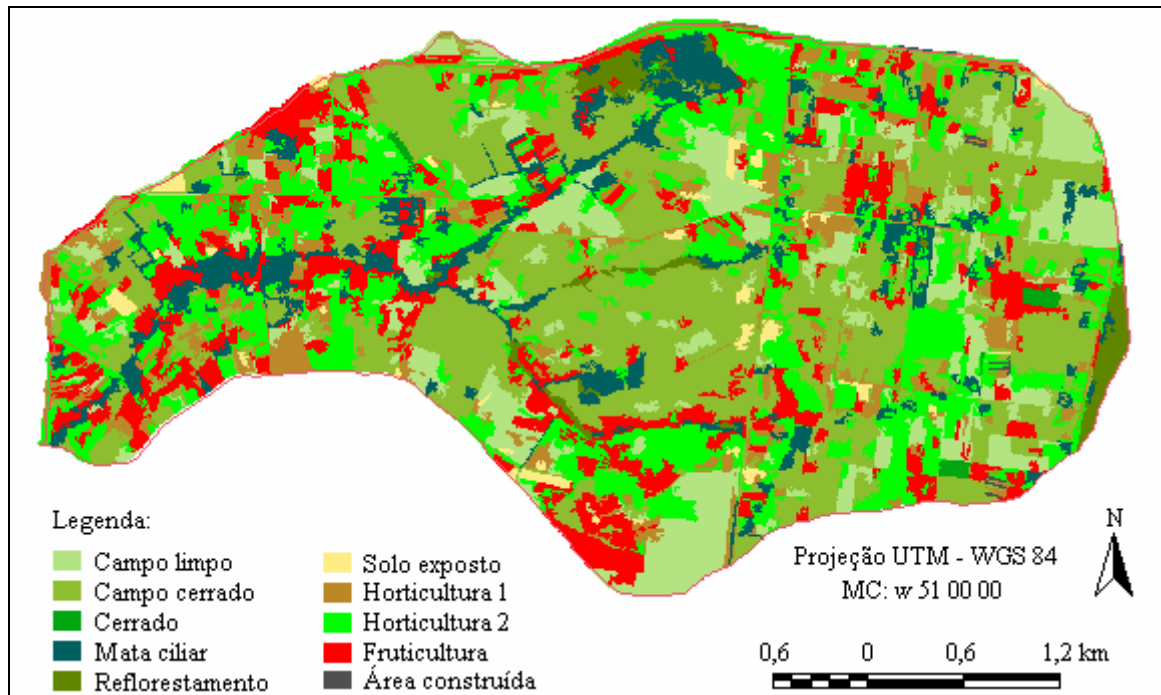


Figura 6.18 – Classificação da imagem pancromática do SPOT-5 com resolução espacial de 5 m obtida pela reamostragem da imagem pan 2,5 m.

6.2.5.5 – Imagem pancromática do SPOT-5 com resolução espacial de 10 m obtida pela reamostragem da imagem pan 2,5 m.

A figura 6.19 ilustra a classificação da imagem pancromática do SPOT-5 com resolução espacial de 10 m obtida pela reamostragem de imagem pan 2,5m.

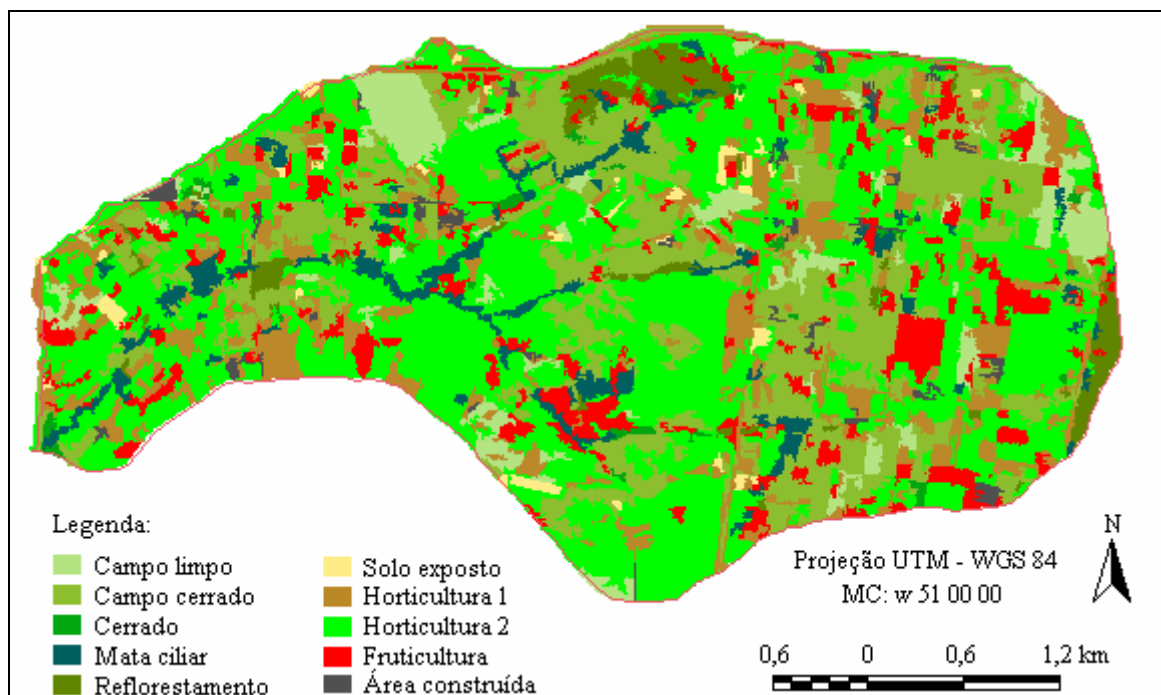


Figura 6.19 – Classificação da imagem pancromática do SPOT-5 com resolução espacial de 10 m obtida pela reamostragem da imagem pan 2,5 m.

A Tabela 6.7 mostra os valores de medidas de áreas das classes temáticas correspondentes a imagem pancromática com resolução de 10 m e os respectivos erros relativos.

Tabela 6.7 – Áreas dos temas mapeados pela interpretação visual e pelo classificador ClaTex para a imagem pancromática do SPOT-5 de 10 m reamostrada pela pan 2,5 m e o erro relativo das áreas das classes temáticas geradas pelo classificador.

Classes temáticas	Cálculo das áreas				Erro relativo (%)
	Verdade terrestre		Classificação		
	km ²	%	km ²	%	
Mata	1,418267	8,65	0,6898	4,21	-51,36
Cerrado	0,24643	1,50	0,1193	0,73	-51,59
Campo limpo	6,503224	39,67	0,9519551	5,81	-85,36
Campo cerrado	3,939784	24,03	3,5281551	21,52	-10,45
Horticultura 1	1,739091	10,61	2,0490034	12,50	17,82
Horticultura 2	0,866751	5,29	6,826617	41,64	687,61
Fruticultura	0,527595	3,22	1,3356517	8,15	153,16
Solo exposto	0,363012	2,21	0,1707	1,04	-52,98
Áreas construídas	0,068757	0,42	0,2101	1,28	205,57
Reservatórios de água	0,026851	0,16	-	-	-
Reflorestamento	0,485127	2,96	0,5137517	3,13	5,90
Estradas pavimentadas	0,109289	0,67	-	-	-
Estradas sem pavimentação	0,100856	0,62	-	-	-
Total	16,395034	100	16,395034	100	

Pela Tabela 6.7 observa-se que ocorreu maior porcentagem de erro relativo com a classe horticultura 2. Algumas áreas correspondentes a campo limpo e campo cerrado foram classificados como pertencente a essa classe. Apesar do erro relativo referente à classe áreas construídas ter sido alto, não se trata de um erro significativo visto que sua área na bacia é pequena.

6.2.6 – Comparação entre as classificações obtidas pelos diferentes produtos para uma área amostral

A seguir são apresentados os resultados das classificações, referentes a uma área amostral, obtidos para as imagens originais do SPOT-5, uma multiespectral e duas pancromáticas,

respectivamente, com resoluções espaciais de 10 m, 5 m e 2,5 m e outra multiespectral do QuickBird-2 com 2,8 m de resolução espacial.

A motivação em se efetuar o procedimento de classificação para uma área amostral foi dada pela meta de avaliar o desempenho do classificador na qualidade da classificação, entre as diferentes imagens. Como as imagens são de datas diferentes, a fim de minimizar essa interferência na modificação espacial de uso e cobertura, escolheu-se uma área que não apresentasse mudanças significativas nas diferentes imagens.

Sob a ótica do desempenho médio da classificação, que é calculado em relação às amostras de treinamento, obteve-se uma porcentagem de 100% em todas as imagens da área amostral, exceto na pancromática do SPOT-5 com 2,5 m de resolução espacial, cujo desempenho médio foi de 95,58%.

A área amostral selecionada tem aproximadamente 17 hectares. Como citado no capítulo 5, utilizou-se como referência na escolha das amostras de treinamento a imagem fusionada do QuickBird-2 (Figura 6.20). A título de ilustração estão delineadas as áreas de algumas classes.

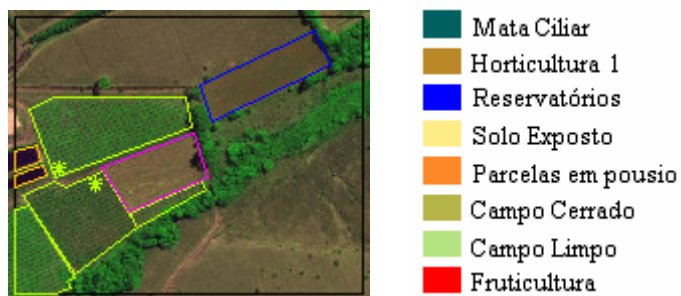


Figura 6.20 - Composição colorida 2(B)3(R)4(G) do QuickBird-2 fusionada, 0,70 m de resolução espacial. Em destaque, áreas de referência: laranja – reservatórios; verde – fruticultura, azul – horticultura1 e rosa – parcela em pousio. (*) medição das áreas com GPS. E, ao lado, apresentação da legenda utilizada para a classificação da área amostral.

Antes da análise de comparação quanto à exatidão das áreas classificadas, efetuou-se uma avaliação individual para cada imagem.

A seguir são apresentadas as classificações obtidas para cada imagem, tendo sido, também, efetuado uma comparação visual entre o resultado obtido na classificação e a imagem de origem.

Com relação à imagem multiespectral do SPOT-5 com resolução espacial de 10 m (Figura 6.21), utilizou-se as medidas de textura: média vetor soma e média vetor diferença calculadas a partir da banda 2 e energia vetor soma determinadas pela banda 3 (infravermelho próximo). Entretanto, ao se comparar visualmente a imagem classificada com a imagem original, observou-se que algumas áreas, não utilizadas no cálculo da matriz de confusão, foram classificadas erroneamente. Na Figura 6.21c, estão identificadas por setas as áreas nas quais houve maior ocorrência desse tipo de erro. O problema ocorreu devido à similaridade textural dessas áreas com as reais áreas de fruticultura apresentada na banda 3, que corresponde a uma das bandas utilizadas no processo de classificação.




Figura 6.21 – Imagem multiespectral do SPOT-5, resolução espacial 10 m, (a), (b) e (c), respectivamente, composição colorida 1(B)2(R)3(G) realçada, imagem rotulada a partir das banda 1, 2 e 3 com limiares de 10/20 (similaridade/área) e imagem classificada.

No que se refere à imagem pancromática do SPOT-5 com 5 m de resolução espacial (Figura 6.22), utilizou-se as medidas de textura: média vetor soma e dissimilaridade. Avaliando-se a cena, verifica-se que não houve problemas significativos na classificação, apenas algumas não foram satisfatoriamente classificadas devido ao delineamento das amostras.



Figura 6.22 – Imagem pancromática do SPOT-5 com resolução espacial de 5 m, (a) original, (b) rotulada com limiares de 6/70 (similaridade/área) e imagem classificada (c).

Para a imagem pancromática do SPOT-5 com resolução espacial de 2,5 m, as medidas utilizadas foram: entropia, média vetor soma e energia vetor soma. O desempenho médio foi de 95,58%. As confusões ocorreram nas amostras referentes às classes: reservatório

classificadas como parcelas em pousio; e campo limpo classificadas como fruticultura, (Tabela 6.8).

Tabela 6.8 – Matriz de confusão a partir da imagem pancromática de 2,5 m do SPOT-5 (valores em %)

Classes	1	2	3	4	5	6	7	8
1	100	0,00	0,00	0,00	0,00	0,00	0,00	0,00
2	0,00	100	0,00	0,00	0,00	0,00	0,00	0,00
3	0,00	0,00	0,00	0,00	100	0,00	0,00	0,00
4	0,00	0,00	0,00	100	0,00	0,00	0,00	0,00
5	0,00	0,00	0,00	0,00	100	0,00	0,00	0,00
6	0,00	0,00	0,00	0,00	0,00	100	0,00	0,00
7	0,00	0,00	0,00	0,00	0,00	0,00	90,53	9,47
8	0,00	0,00	0,00	0,00	0,00	0,00	0,00	100

Legenda:
 1 - Mata ciliar 3 - Reservatórios 5 - Parcelas em pousio 7 - Campo limpo
 2 - Horticultural 4 - Solo Exposto 6 - Campo cerrado 8 - Fruticultura

Como se observa na Figura 6.23, toda a área referente aos reservatórios foi classificada erroneamente como parcelas em pousio (elipse preta), e uma amostra de campo limpo classificada também como parcelas em pousio (elipse branca). Esse tipo de problema pode ser atribuído à similaridade conjunta dos padrões espectrais e espaciais.



Figura 6.23 – Imagem pancromática do SPOT-5 com resolução espacial de 2,5 m, (a), (b) e (c), respectivamente, imagem original, imagem rotulada com limiares de 8/140 (similaridade/área) e imagem classificada.

Referindo-se à Figura 6.23, pela comparação visual entre a imagem original e a imagem classificada, lembrando que a base da interpretação é a imagem fundida (Figura 6.20), observa-se que de forma geral a classificação não foi satisfatória, pois diversas áreas que não foram utilizadas para o cálculo da matriz de confusão foram classificadas erroneamente e estão identificadas por setas brancas na Figura 6.23. A seta 1, de acordo com o reconhecimento de campo e interpretação da imagem fusionada, corresponde à fruticultura. Porém, analisando-se visualmente a imagem pancromática, observa-se que há uma leve mudança textural em relação à vizinhança, que também é área de fruticultura.

Isso mostra que se trata de uma interferência detectada na imagem de origem, podendo ser uma área suscetível a uma classificação errada. No caso das áreas indicadas pelas demais setas, o problema de confusão pode ser explicado pela semelhança textural dessas regiões com outras classes, sendo também influenciada pelo problema de delineamento de borda das áreas amostrais selecionadas por cada classe na fase de treinamento.

Comparando-se os desempenhos médios obtidos para as imagens pancromáticas de 5 m e 2,5 m, não era de se esperar que para a imagem de 2,5 m houvesse um menor desempenho. Entretanto, esse problema pode ser justificado pela própria seleção das amostras. Como se observa na imagem pan 5 m, há poucas segmentações caracterizadas por maiores áreas, ao contrário da imagem pan 2,5 m. Como a classificação é calculada baseando-se na distribuição espacial dos pixels na amostra, a probabilidade de confusão será maior em imagens com pequenas segmentações, visto que essas áreas tendem a agrupar pixels de níveis de cinza semelhante, caracterizando-se por áreas homogêneas.

No tocante à imagem multiespectral do QuickBird-2, obteve-se um desempenho médio de 100% ao utilizar as medidas de textura: média vetor soma, homogeneidade e contraste, extraídas pela banda 3 (vermelho). A Figura 6.24 mostra o resultado da imagem classificada. Avaliando-se visualmente o resultado da classificação (Figura 6.24c), comparando-o com a composição colorida (Figura 6.24a), vê-se que houve confusão em alguns locais na classificação, destacadas por setas pretas. As causas de tais confusões podem ser atribuídas ao problema de delineamento dessas áreas. Assim sendo, como em tais áreas não predomina um padrão textural, mas sim uma mistura de padrões, verifica-se o problema observado na classificação. Lembra-se que esse comentário é referente à banda espectral utilizada para a extração das medidas texturais.



Figura 6.24 – Imagem multiespectral do QuickBird-2, resolução espacial de 2,8 m, (a) composição colorida 2(B)3(R)4(G) realçada, (b) imagem rotulada a partir das banda 1,2 e 3 com limiares de 7/100 (similaridade/área) e (c) imagem classificada.

Outras pequenas áreas foram classificadas erroneamente, devido ao próprio delineamento de borda das amostras, a exemplo da área indicada pela seta branca.

A partir dos resultados das classificações, verifica-se que um dos fatores que comprometeram na exatidão das áreas das classes foi o insatisfatório delineamento das regiões, causado pelo desempenho limitado do algoritmo de segmentação utilizado. Nota-se que, com a boa resolução espacial, o algoritmo crescimento por regiões fica mais suscetível a segmentação excessiva, formando, na maioria das vezes, dentro de uma área correspondente a uma feição, pequenos fragmentos.

Como na classificação supervisionada por regiões o algoritmo gera para cada classe uma ‘assinatura’, que é baseada no reconhecimento dos padrões das suas amostras de treinamento, se houver problema no delineamento das regiões dessas amostras, poderá haver comprometimento na caracterização das assinaturas. Esse fator provavelmente interferirá na classificação das demais regiões, visto que a associação das regiões a uma das classes propostas é realizada com base em uma regra de decisão.

A seguir é apresentada a quantificação em hectares das classes temáticas referentes às imagens classificadas e da verdade de campo (Tabela 6.9).

Tabela 6.9 – Medidas das áreas em hectares das classes temáticas para a área amostral.

Classes temáticas	Mapas temáticos (medidas em hectares)				
	Verdade de campo	QuickBird-2 multispectral 2,8 m	SPOT-5 pancromática 2,5 m	SPOT-5 pancromática 5 m	SPOT-5 multispectral 10 m
Fruticultura	3,38	3,90	3,93	3,62	4,57
Campo limpo	5,73	5,26	3,76	6,37	4,84
Campo cerrado	2,63	2,39	1,71	1,55	1,64
Parcelas em pousio	0,98	1,05	3,89	0,86	1,15
Solo exposto	0,55	0,13	0,14	0,14	0,18
Reservatórios	0,15	0,18	0,00	0,28	0,22
Horticultural	0,86	0,98	0,00	1,43	1,19
Mata ciliar	2,74	3,13	3,60	2,78	3,23
Área total	17,02	17,02	17,02	17,02	17,02

Pela Tabela 6.9 fica perceptível as diferenças de áreas da mesma classe pelos diferentes produtos.

Para as classes fruticultura e mata ciliar, observa-se que há superestimação dessas áreas em todos os mapas temáticos analisados.

No caso da imagem pancromática do SPOT-5 de 2,5 m de resolução espacial, os maiores problemas foram causados pela não identificação do classificador das áreas de reservatórios e horticultura 1, como se observa na Tabela 6.9. Pela análise visual, as áreas de reservatórios foram classificadas como parcelas em pousio, contribuindo para o diminuição na exatidão dessa classe, e, a área correspondente à horticultura 1 foi classificada como mata ciliar.

Comparando-se as medidas de áreas para todas as classes com as correspondentes à verdade de campo, observa-se que para as classes fruticultura e mata ciliar houve maior exatidão no mapeamento gerado pela imagem pancromática do SPOT-5 com 5 m de resolução espacial. Com relação às classes campo cerrado, campo limpo, parcelas em pousio, reservatórios e horticultura, a maior exatidão ocorreu no mapa temático obtido pela imagem multiespectral do QuickBird-2. Verificou-se, ainda, que o mapa de pior qualidade na obtenção das informações, foi gerado pela imagem pancromática do SPOT-5 com 2,5 m de resolução espacial.

Portanto, nesse caso, o mapeamento temático gerado pela imagem multiespectral do QuickBird-2 foi o que mais se aproximou com a verdade de campo.

7 – CONCLUSÕES E RECOMENDAÇÕES

Esta pesquisa teve como propósito geral avaliar a aplicabilidade de diferentes imagens de sensoriamento remoto de alta e muito alta resolução espacial para discriminação de alvos em uma área tipicamente rural. Utilizou-se o software SPRING para o processamento digital das imagens, por meio do classificador textural ClaTex.

Com vistas aos objetivos propostos, os resultados obtidos mostraram que:

- Pela interpretação visual das imagens, um produto de muito alta resolução espacial apresenta alto nível de detalhamento na identificação dos alvos no que se refere a imagens multiespectrais;
- Nas imagens pancromáticas, apesar da diferenciação de forma e textura entre alguns alvos, a baixa resolução espectral causa dificuldades na consistente identificação das feições, em situações com predominância de coberturas vegetais, com variações como a de cerrado – campo cerrado, campo limpo, campo sujo, etc.
- Em relação à utilização do software SPRING, verificou-se que quanto maior a resolução espacial da imagem, maior foi o tempo computacional de processamento. Por se tratar de um software recomendado para imagens de média e alta resolução, verificou-se que no uso em imagem de muito alta resolução, o maior problema encontrado foi a quantidade de memória requerida;
- No que se refere ao uso das medidas de Haralick para a extração de textura observa-se que o processo de classificação é exaustivo, pois não há como se estabelecer um critério de quais seriam as melhores medidas de textura para maximizar a qualidade da classificação;
- Pelos resultados obtidos utilizando-se a função de seleção automática das medidas de textura, verificou-se que, nas imagens analisadas, o desempenho médio de classificação foi abaixo do resultado obtido pelo processo manual;
- A medida de textura que apresentou maior fator de discriminação entre duas classes foi a média vetor soma. Entretanto, ao utilizar apenas essa medida, não se obteve altos desempenhos médios;
- Os resultados do desempenho médio de classificação foram maiores para as imagens multiespectrais. Isso mostra que no caso das imagens pancromáticas, apesar da alta resolução espacial para a classificação, o principal fator interferente

- para o aumento do desempenho médio de classificação é a limitada qualidade espectral;
- Quanto à influência da resolução espacial no resultado final da classificação, verificou-se que a reamostragem dos pixels na escala 1:2, provocou um decaimento no desempenho médio da classificação em torno de 10%;
 - Ocorreram problemas de delineamentos dos alvos, tendo sido ocasionado por dois fatores: semelhança espectral dos alvos, principalmente nas imagens pancromáticas; e/ou, pela melhora da resolução espacial, sendo perceptível a heterogeneidade estrutural de alguns alvos o que provocou excessiva fragmentação nessas regiões;
 - O problema de delineamento dos alvos interferiu na inclusão das classes identificadas pela interpretação visual: estradas sem pavimentação, estradas pavimentadas e reservatórios. Foi verificado que a não confiabilidade das amostras aumenta a confusão entre as classes e, por conseqüência, diminui o desempenho médio de classificação;
 - Para todas as imagens classificadas, uma das possíveis causas da classificação errônea é atribuída ao desempenho limitado do algoritmo de segmentação, que por sua vez gerou em algumas regiões delineamentos insatisfatórios;
 - Apesar da extração de amostras representativas, exceto para a imagem pancromática de 5 m, na qual alguns locais correspondentes aos pontos geográficos escolhidos não foram selecionados por problema de delimitação, verificou-se que a confiabilidade da classificação não pode ser baseada apenas na análise da matriz de confusão. Significa dizer que um bom desempenho médio nas amostras não garante que as demais áreas da imagem venham a ser classificadas corretamente. Isso ficou melhor comprovado nas análises das classificações obtidas para a área amostral, cujo desempenho médio de classificação para a maioria das imagens foi de 100%;
 - Como se trata de uma classificação por regiões, se as áreas não estiverem bem delimitadas, a probabilidade que ocorrer classificações erradas nessas áreas aumenta;
 - Avaliando-se os resultados de classificação obtidos para a área amostral, observa-se que, pela comparação entre as medidas de áreas para todas as classes com as correspondentes à verdade de campo, para as classes fruticultura e mata ciliar houve menor erro no mapeamento gerado pela imagem pancromática do SPOT-5 com 5 m de resolução espacial; e, para as classes campo cerrado, campo limpo,

parcelas em pousio, reservatórios e horticultura 1, houve menor erro no mapa temático obtido pela imagem multiespectral do QuickBird-2;

- Ainda para a área amostral, verifica-se que o mapa de pior qualidade foi gerado pela imagem pancromática do SPOT-5 com 2,5 m de resolução espacial; e, o mapeamento temático gerado pela imagem multiespectral do QuickBird-2 foi o que mais se aproximou com a verdade de campo;
- O grau de confiabilidade do mapa temático gerado não deve ser associado apenas à acurácia apresentada pela matriz de confusão, é relevante a avaliação visual do mapa temático gerado.

Como recomendação para futuros trabalhos sugere-se:

- Estudos com outros algoritmos de segmentação em busca da boa delimitação dos alvos de interesse em imagens de muito alta resolução espacial, principalmente quando se trata de classes de diferentes coberturas vegetais e representadas por polígonos de dimensões variadas;
- Elaboração de mapas temáticos das imagens estudadas por outras técnicas de classificação, que também considerem a informação contextual, como as classificações as orientadas a objeto. Dessa forma, atributos adicionais, como forma, relação entre os objetos e sua vizinhança, etc., poderão melhorar o resultado da classificação;
- Avaliar a quantidade de amostras necessárias para se conseguir determinada acurácia na classificação.

REFERÊNCIAS BIBLIOGRÁFICAS

- Albregtsen, F. (2003). "Statistical Texture Analysis Static or Adaptive?" Disponível em: <http://folk.uio.no/inf386/foiler7.pdf>. Acesso: 20 de dezembro de 2004.
- Atkinson, P.M. (2004). "Spatially weighted supervised classification for remote sensing." *International Journal of Applied Earth Observation and Geoinformation*, **5** (4), 277–291.
- Baraldi, A., Parmiggiani, F. (1995). "An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters." *IEEE Transactions on Geoscience and Remote Sensing*, **33**(2), 293-304.
- Barnsley, M.J. e Barr, S.L. (1996). "Inferring urban land use from satellite sensor images using kernel-based spatial reclassification." *Photogrammetric Engineering & Remote Sensing*, **62**(8), 949-958.
- Bastiaanssen, W.G.M., Molden, D.J. e Makin, I.W. (2000). "Remote sensing for irrigated agriculture: examples from research and possible applications." *Agricultural Water Management*, **46** (2), 137-155.
- Berberoglu, S., Lloyd, C.D., Atkinson, P.M. e Curran, P.J. (2000). "The integration of spectral and textural information using neural networks for land cover mapping in the Mediterranean." *Computers & Geosciences*, **26** (4), 385-396.
- Câmara, G., Souza, R.C.M., Freitas U.M. e Garrido, J. (1996). "SPRING: Integrating remote sensing and GIS by object-oriented data modeling." *Computers & Graphics*, **20**(3), 395-403.
- Campana, N.A., Monteiro, M.P., Cordeiro Netto, O.M. e Koide, S. (1998). *Inventário Hidrogeológico e dos Recursos Hídricos Superficiais do Distrito Federal*. MMA/SRH/SEMATEC-DF/IEMA-DF/UNB, Brasília.
- Campos, J.E.G. (2004). "Hidrogeologia do Distrito Federal: bases para a gestão dos recursos hídricos subterrâneos." *Revista Brasileira de Geociências*, **34**(1), 41-48.
- Carr, J.R. (1996). "Spectral and textural classification of single and multiple band digital images." *Computers & Geosciences*, **22** (8), 849-865.
- Chen, S., Chen, L., Liu, Q., Lib, X e Tan, Q. (2005). "Remote sensing and GIS-based integrated analysis of coastal changes and their environmental impacts in Lingding Bay, Pearl River Estuary, South China." *Ocean & Coastal Management*, **48** (1), 65–83.

- DigitalGlobe (2004). Disponível em: <http://www.digitalglobe.com/>. Acesso: 15 de setembro de 2004.
- Florenzano, T.G. (2002). *Imagens de Satélite para Estudos Ambientais*. Oficina de textos, São Paulo, 97p.
- Fonseca, L.M.G. (2000). “Processamento Digital de Imagens.” Disponível em: <http://www.dpi.inpe.br/~leila/ser437/ser437.html>. Acesso em: 27 de fevereiro de 2004.
- Foody, G.M.(2002). “Status of land cover classification accuracy assessment.” *Remote Sensing of Environment*, **88**(1-2), 185-201.
- Franklin, S.E., Maudie, A. e Lavigne, M.B (2001). “Using spatial co-ocurrence texture to increase forest structure and species composition classification accuracy.” *Photogrammetric Engineering and Remote Sensing*, **67**(7), 849-855.
- Freitas, A.J. (2000). “Gestão de Recursos Hídricos.” In: Silva, D.D. e Pruski, F.F.(eds.) *Gestão de Recursos Hídricos: aspectos legais, econômicos, administrativos e sociais*. MMA-SRH, UFV, ABRH, Brasília, Brasil, 659p.
- Fukue, K., Shimoda, H. e Sakata, T. (1998). “Spatial landcover classification using a neural network driven by co-occurrence matrix for landcover elements.” *Proceedings of the International Geoscience and Remote Sensing Symposium, IGARSS '98*, **2**, 1137-1139, Seattle, EUA.
- Gong, P. e Howarth, P.J. (1990). “The use of structure information for improving land-cover classification accuracies at the rural-urban fringe.” *Photogrammetric Engineering & Remote Sensing*, **56**(1), 67-73.
- Gonzalez, R.C. e Woods, R.E. (2002). *Digital Image Processing*. Prentice Hall, Nova Jérsei, 2. ed., 793p.
- Greenspan, H. Goodman, R., Chellappa, R. e Anderson, C.H. (1994). “Learning texture discrimination rules in a multiresolution system.” *IEEE Transaction on Pattern Analysis and Machine Intelligence*, **16**(9), 894-901.
- Hall-Beyer, M. (2000). “GLCM texture: A tutorial.” Disponível em: http://www.ucalgary.ca/~mhallbey/texture/texture_tutorial.html. Acesso: 05 de novembro de 2004.
- Haralick, R.M., Shanmugam, K. e Dinstein, I. (1973). “Textures features for image classification.” *IEEE Transactions on Systems, Man and Cybernetics*, **3**(6), 610-621.
- Haralick, R.M. (1979). “Statistical and structural approaches to texture.” *Proceedings of the IEEE*, **67**(5), 786-804.

- He, D.C., Wang, L. e Guibert, J. (1988) “Texture discrimination based on an optimal utilization of texture features.” *Pattern Recognition*, **21**(2), 141-146.
- Ierodiaconou, D., Laurenson, L., Leblanc, M., Stagnitti, F., Duff, G. e Salzman, S. (2005). “Multi-temporal land use mapping using remotely sensed techniques and the integration of pollutant load model in a GIS.” In: Chen, Y., Takara, K., Clukie, I, Smedt, F.H. (eds) *GIS and Remote Sensing in Hydrology, Water Resources and Environment*, IAHS, **289**, 343-352.
- INPE (2004). “SPRING – Manual do usuário versão 4.1.” Disponível em: www.dpi.inpe.br/spring. Acesso em : 15 de fevereiro de 2005.
- Jiren, L., Zhedan, C., Fuchuan, X., Jian, L., Wen, W. e Lei, C. (1997). “Application of remote sensing and GIS techniques for irrigable land investigation.” In: Baumgartner, M.F, Schultz, G.A. e Johnson A.I. (eds.) *Remote Sensing and Geographic Information Systems for Design and Operation of Water Resources Systems*. IAHS Publication, **242**, 17-21.
- Lelong, C.C.D.; Thong-Chane, A. (2003). “Application of textural analysis on very high resolution panchromatic images to map coffee orchards in Uganda.” *Proceedings. of the International Geoscience and Remote Sensing Symposium, IGARSS'03*, **2**, 1007-1009, Toulouse, França.
- Lepsch, I. F. (1993). *Solos: formação e conservação*. Editora Melhoramentos, São Paulo, 5ª edição, 157p.
- Lillesand, T.M. e Kiefer, R.W. (1994). *Remote Sensing and Image Interpretation*. John Wiley & Sons, Nova Iorque, 3. ed., 750p.
- Marceu, D.J., Howarth, P.J., Dubois, J.M., Gratton, D.J. (1990). “Evaluation of the grey-level co-occurrence matrix method for land-cover classification using SPOT Imagery.” *IEEE transactions on Geoscience and Remote Sensing*, **28**(4), 513-519.
- Martínez, C. e Calera, A. (2001). “Irrigated crop area estimation from thematic map using Landsat TM Imagery in La Mancha (Spain).” *Photogrammetric Engineering and Remote Sensing*, **67**(10), 1177-1184.
- Mendes, C.A.B. e Cirilo, J.A. (2001). *Geoprocessamento em Recursos Hídricos – Princípios, Integração e Aplicação*, Editora ABRH, 533p.
- Meneses, P.R. e Netto, J.S.M. (2001). *Sensoriamento Remoto – Reflectância dos Alvos*, Editora UnB, 262p.
- Morales, I.D., Moctezuma, M. e Parmmiggiani, F. (2003). “Urban and non urban area classification by texture characteristics and data fusion.” *Proceedings. of the*

International Geoscience and Remote Sensing Symposium, IGARSS '03, **6**, 3504-3506, Toulouse, França.

- Moreira, M.A. (2001). *Fundamentos do sensoriamento remoto e metodologias de aplicação*. INPE, São José dos Campos, 250p.
- Nascimento, A.C., Campana, N.A e Eid, N.J. (2000). “Reconstituição de vazões mínimas, estudo de caso: bacia do capão comprido.” *Anais do I Simpósio de Recursos Hídricos do Centro-Oeste*, (meio digital – CD-Rom), Brasília-DF, Brasil.
- Nascimento, J.P.R., Madeira, H.M.F. e Pedrini, H. (2003). “Classificação de imagens utilizando descritores estatísticos de textura.” *Anais do XI Simpósio Brasileiro de Sensoriamento Remoto*, 2099-2106, Belo Horizonte, Brasil.
- Novo, E.M.L.M. (1992). *Sensoriamento Remoto: princípios e aplicações*. Editora Edgard Blucher, 308p.
- Olalla, M. S. F., Calera, A. e Domínguez, A. (2003). “Monitoring irrigation water use by combining irrigation advisory service, and remotely sensed data with a geographic information system.” *Agricultural Water Management*, **61**(2), 111-124.
- Prenzel, B. (2004). “Remote sensing-based quantification of land-cover and land-use change for planning.” *Progress in Planning*, **61** (4), 281–299.
- Raptis, V.S., Vaughan, R.A. e Wright, G.G. (2003). “The effect of scaling on landcover classification from satellite data.” *Computers & Geosciences*, **29**(6), 705–714.
- Reatto, A., Martins, E.S., Cardoso, E.A., Spera, S.T., Carvalho Jr., O.A.C., Silva, A.V. e Farias, M.F.R. (2003). *Levantamento de Reconhecimento de Solos de Alta Intensidade do Alto Curso do Rio Descoberto, DF/GO, escala 1:100.000*. Boletim de Pesquisa e Desenvolvimento N° 92. Embrapa Cerrados, Distrito Federal, Brasil.
- Rennó, C. D., Freitas, C.C. e Sant’anna, S.J.S. (1998). “A system for region image classification based on textural measures.” *Anais do IX Simpósio Brasileiro de Sensoriamento Remoto*, 1195-1202, Santos, Brasil.
- Roerink, G.J., Bastiaanssen, W.G.M, Chambouleyron, J. e Meneti, M. (1997). “Relating crop water consumption to irrigation water supply by remote sensing.” *Water Resources Management*, **11**, 445-465.
- Rudorff, B.F.T. (2004). “Produtos de Sensoriamento Remoto.” Disponível em: <http://www.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm> . Acesso: 22 de Março de 2004.

- Ruiz, L.A., Fdez-Sarría, A. e Recio, J.A. (2002). "Evaluation of texture analysis techniques to characterize vegetation." *Proceedings of the First International Symposium on Recent Advances in Quantitative Remote Sensing*, 514-521, Valência, Espanha.
- Ruiz, L.A., Iñán, I., Baridón, J.E., Lanfranco, J.W. (1998). "Combining multispectral images and selected textural features from high resolution images to improve discrimination of forest canopies." *Image and Signal Processing for Remote Sensing IV*, **3500**, 124-134, Barcelona, Espanha.
- Ruiz, L.A., Fdez-Sarría, A. e Recio, J.A. (2004). "Texture feature extraction for classification of remote sensing data using wavelet decomposition: a comparative study." *The Twentieth Congress of the International Society for Photogrammetry and Remote Sensing*, 1118-1122, Stambul, Turquia.
- Sabins Jr., F.F. (1987). *Remote Sensing: principles and interpretation*. W.H. Freeman, Nova Iorque, 2. ed., 429p.
- Schwartz, R.W. e Pedrini, H. (2003). "Método para classificação de imagens baseada em matrizes de co-ocorrência utilizando características de textura." *Anais do III Colóquio Brasileiro de Ciências Geodésicas*, (meio digital – CD-Rom), Curitiba, Brasil.
- Seelan, S.K., Laguate, S., Casady, G.M., Seielstad, G.A. (2003). "Remote sensing applications for precision agriculture: a learning community approach." *Remote Sensing of Environment*, **88**(1-2), 157–169.
- Shaban, M.A. e Dikshit, O. (1998). "Textural classification of high resolution digital satellite imagery." *Proceedings of the International Geoscience and Remote Sensing Symposium, IGARSS '98*, **5**, 2590-2592, Seattle, EUA.
- Shimabukuro, M.T. (1996). *Avaliação de Classificadores Espectrais de Imagens Landsat-TM em Áreas Rurais Densamente Ocupadas: o caso da região de Brotas e Torrinha*. Dissertação de Mestrado, Universidade Estadual de Campinas, Instituto de Biologia, Campinas, SP, 177p.
- Soares, J.V., Rennó, C.D., Formaggio, A.R., Yanasse, C.C.F. e Frery, A.C. (1997). "An investigation of the selection of texture features for crop discrimination using SAR imagery." *Remote Sensing of Environment*, **59**(2), 234-247.
- Souza, I.M., Pereira, M.N., Garcia, L.M.F. e Kurkdjian, M.L.N.O. (2003). "Mapeamento do uso do solo urbano através da classificação por regiões baseada em medidas texturais." *Anais do XI Simpósio Brasileiro de Sensoriamento Remoto*, 1967-1969, Belo Horizonte, Brasil.

- Spot Image (2004). Disponível em : www.spotimage.fr/. Acesso em : 01 de junho de 2004.
- Treitz, P. e Rogan, J. (2004). “Remote sensing for mapping and monitoring land-cover and land-use change – an introduction.” *Progress in Planning*, **61** (4), 269–279.
- Tso, B.e Olsen, R.C.(2004). “Scene classification using combined spectral, textual, and contextual information.” *Proceedings of the SPIE, Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery X*, **5425**, 135-146, Orlando, EUA.
- Tuceryan, M. e Jain, A.K. (1998).“Texture Analysis”.In: Chen, C.H, Pau, L.F. e Wang, P.S.P. (eds.) *Handbook of Pattern Recognition and Computer Vision*, 2ed., World Scientific Publishing Co., 207-248.
- Ulaby, F.T., Kouyate, F., Brisco, B. e Lee, T.H.W. (1986). “Textural information in SAR Images.” *IEEE Transactions on Geoscience and Remote Sensing*, **24**(2), 235-245.
- Unser, M. (1986). “Sum and difference histograms for texture classification.” *IEEE Transaction on Pattern Analysis and Machine Intelligence*, **8**(1), 118-125.
- Vansteenkiste, E., Gautama, S. e Philips, W. (2004). “Analysing multispectral textures in very high resolution satellite images.” *Proceedings of the International Geoscience and Remote Sensing Symposium, IGARSS'04*, **5**, 3062-3065, Anchorage, Alaska.
- Wang, L., Sousa, W.P, Gong, P. e Biging, G.S. (2004). “Comparison of IKONOS and QuickBird images for mapping mangrove species on the Caribbean coast of Panamá.” *Remote Sensing of Environment*, **91**(3-4), 432–440.
- Welch, R.M., Kuo, K. e Senguptura, S.K. (1990). “Cloud and surface textural features in polar regions.” *IEEE transactions on Geoscience and Remote Sensing*, **28**(4), 520-528.
- Weske, M., Vossen, G., Medeiros, C.B. e Pires, F. (1998). “Workflow management in geoprocessing applications.” *Proceedings of the 6th International Symposium on Advances in Geographic Information Systems*, 88-93, Washington, EUA.
- Wikantika, K., Uchida, S., Yamamoto, Y. e Harto, A.B. (2002). “Investigation of classification accuracy of vegetable field in mountainous area with spectral and textural aspects derived from the LANDSAT-ETM.” *Proceedings. of the International Geoscience and Remote Sensing Symposium, IGARSS '02*, **5**, 2793-2795, Ibaraki, Japão.

APÊNDICES

APÊNDICE A – FORMULAÇÃO MATEMÁTICA DE MEDIDAS DE DISTÂNCIA UTILIZADAS COMO REGRA DE DECISÃO (Mendes e Cirilo, 2001).

A.1 – Distância de Battacharya

$$D_{\text{Bat}} = \frac{1}{8} (M_2 - M_1)^T \left[\frac{\text{Cov}_1 + \text{Cov}_2}{2} \right]^{-1} (M_2 - M_1) + \frac{1}{2} \ln \frac{|\text{Cov}_1 + \text{Cov}_2|}{2 \sqrt{|\text{Cov}_1| |\text{Cov}_2|}} \quad \text{Equação (A.1)}$$

A.2 – Distância de Mahalanobis

$$D = (X - M_i)^T (\text{Cov}_i^{-1}) (X - M_i) \quad \text{Equação (A.2)}$$

A.3 – Distância de Euclidiana

$$D_{\text{euc}} = \sqrt{(X - M_i)^T (X - M_i)} \quad \text{Equação (A.3)}$$

A.4 – Distância Mínima

$$DM_{xyi} = \sqrt{\sum_{a=1}^n (M_{ia} - M_{xya})^2} \quad \text{Equação (A.4)}$$

Onde:

- D_{bat} = distância de Battacharya;
- D = distância de Mahalanobis;
- D_{euc} = distância Euclidiana;
- DM_{xyi} = distância de Mínima do pixel “x,y” para a classe “i”;
- i = determinada da classe; $i=1,2$;
- M_i = vetor média da classe “i”;
- Cov_i = matriz de covariância da classe “i”;
- X = vetor do pixel analisado;
- a = determinada da classe;
- X_{xya} = pixel “x,y” na banda “a”;
- n = número de bandas;
- $(\dots)^{-1}$ = inversa da matriz;
- $(\dots)^T$ = transposta da matriz.

O pixel é associado à classe “i” que apresenta menor distância.

APÊNDICE B – FOTOS REFERENTES À CARACTERIZAÇÃO DA SUB-BACIA DO CAPÃO COMPRIDO



a) Eucaliptos



b) Cerrado



c) À frente Campo limpo e ao fundo Campo cerrado



d) Mata ciliar, no centro da imagem



e) Cultivo de goiaba



f) Cultivo de hortaliças

Figura B.1 – Fotografias de uso e coberturas vegetais na área em estudo.

APÊNDICE C – DESEMPENHOS MÉDIOS OBTIDOS PARA A CLASSIFICAÇÃO DA IMAGEM MULTIESPECTRAL DO SPOT-5, UTILIZANDO-SE PARA CADA CAMADA DE TEXTURA AS MEDIDAS DE TEXTURAS INDIVIDUALMENTE.

Tabela C.1 – Desempenhos médios obtidos na classificação da imagem multiespectral do SPOT-5 para cada medida de textura

Medidas de texturas	Camadas de texturas		
	Banda 2 (verde)	Banda 3 (vermelho)	Banda 4 (infravermelho próximo)
Entropia	22,10 %	36,38 %	14,92 %
Contraste	12,65 %	28,07 %	16,27 %
Energia	8,70 %	7,50 %	12,97 %
Homogeneidade	16,19 %	11,17 %	16,60 %
Dissimilaridade	5,47 %	14,40 %	10,76 %
Correlação	31,52 %	32,17 %	28,10 %
Chi-quadrado	26,38 %	17,05 %	47,72 %
Média vetor soma	39,62 %	51,17 %	19,13 %
Variância vetor soma	15,86 %	18,65 %	17,89 %
Entropia vetor soma	21,19 %	8,44 %	14,46 %
Energia vetor soma	18,73 %	8,24 %	19,31 %
Média vetor diferença	5,47 %	14,40 %	10,76 %
Variância vetor diferença	14,47 %	17,96 %	12,01 %
Entropia vetor diferença	16,34 %	17,54 %	13,10 %
Energia vetor diferença	14,44 %	15,35 %	14,63 %
Contraste vetor diferença	12,65 %	28,07 %	16,27 %
Cluster Shade	33,36 %	7,38 %	14,03 %
Cluster Prominence	19,06 %	23,50 %	31,41 %

APÊNDICE D – MEDIDAS DE TEXTURA SELECIONADAS PELO FATOR DISCRIMINANTE ENTRE DUAS CLASSES.

Tabela D.1- Medidas selecionadas para a imagem multiespectral do SPOT-5

Par de classes	Medidas de textura	Camada de textura
Campo Cerrado e Campo limpo	Média vetor soma	b2 (vermelho)
Campo Cerrado e Cerrado	Média vetor soma	b3 (infraver. próximo)
Campo Cerrado e Área Construída	Média vetor soma	b2 (vermelho)
Campo Cerrado e Fruticultura	Média vetor soma	b2 (vermelho)
Campo Cerrado e Horticultura 2	Média vetor soma	b2 (vermelho)
Campo Cerrado e Horticultura 1	Média vetor soma	b2 (vermelho)
Campo Cerrado e Mata	Média vetor soma	b3 (infraver. próximo)
Campo Cerrado e Reflorestamento	Média vetor soma	b2 (vermelho)
Campo Cerrado e Solo exposto	Média vetor soma	b2 (vermelho)
Campo limpo e Cerrado	Média vetor soma	b2 (vermelho)
Campo limpo e Área Construída	Média vetor soma	b2 (vermelho)
Campo limpo e Fruticultura	Média vetor soma	b2 (vermelho)
Campo limpo e Horticultura 2	Média vetor soma	b3 (infraver. próximo)
Campo limpo e Horticultura 1	Média vetor soma	b2 (vermelho)
Campo limpo e Mata	Homogeneidade	b3 (infraver. próximo)
Campo limpo e Reflorestamento	Média vetor soma	b2 (vermelho)
Campo limpo e Solo exposto	Média vetor soma	b2 (vermelho)
Cerrado e Área Construída	Média vetor diferença	b3 (infraver. próximo)
Cerrado e Fruticultura	Média vetor soma	b2 (vermelho)
Cerrado e Horticultura 2	Média vetor soma	b3 (infraver. próximo)
Cerrado e Horticultura 1	Média vetor soma	b2 (vermelho)
Cerrado e Mata	Média vetor soma	b2 (vermelho)
Cerrado e Reflorestamento	Média vetor soma	b3 (infraver. próximo)
Cerrado e Solo exposto	Média vetor soma	b3 (infraver. próximo)
Área Construída e Fruticultura	Média vetor soma	b2 (vermelho)
Área Construída e Horticultura 2	Média vetor soma	b2 (vermelho)
Área Construída e Horticultura 1	Média vetor soma	b3 (infraver. próximo)
Área Construída e Mata	Média vetor soma	b2 (vermelho)
Área Construída e Reflorestamento	Média vetor soma	b2 (vermelho)
Área Construída e Solo exposto	Média vetor soma	b2 (vermelho)
Fruticultura e Horticultura 2	Média vetor soma	b2 (vermelho)
Fruticultura e Horticultura 1	Média vetor soma	b2 (vermelho)
Fruticultura e Mata	Média vetor soma	b2 (vermelho)
Fruticultura e Reflorestamento	Correlação	b3 (infraver. próximo)
Fruticultura e Solo exposto	Média vetor soma	b2 (vermelho)
Horticultura 2 e Horticultura 1	Média vetor diferença	b3 (infraver. próximo)
Horticultura 2 e Mata	Média vetor soma	b2 (vermelho)
Horticultura 2 e Reflorestamento	Média vetor soma	b3 (infraver. próximo)
Horticultura 2 e Solo exposto	Média vetor soma	b2 (vermelho)
Horticultura 1 e Mata	Média vetor soma	b3 (infraver. próximo)
Horticultura 1 e Reflorestamento	Média vetor soma	b2 (vermelho)
Horticultura 1 e Solo exposto	Média vetor soma	b2 (vermelho)
Mata e Reflorestamento	Média vetor soma	b2 (vermelho)
Mata e Solo exposto	Correlação	b3 (infraver. próximo)
Reflorestamento e Solo exposto	Média vetor soma	b2 (vermelho)

Tabela D.2- Medidas selecionadas para a imagem multiespectral do QuickBird-2.

Par de classes	Medidas de textura	Camada de textura
Campo Cerrado e Campo limpo	Média vetor soma	b3 (vermelho)
Campo Cerrado e Cerrado	Entropia vetor diferença	b3 (vermelho)
Campo Cerrado e Fruticultura	Entropia	b4 (infraverm. próximo)
Campo Cerrado e Horticultura 2	Dissimilaridade	b4 (infraverm. próximo)
Campo Cerrado e Horticultura 1	Média vetor soma	b4 (infraverm. próximo)
Campo Cerrado e Mata	Média vetor soma	b3 (vermelho)
Campo Cerrado e Reflorestamento	Entropia vetor diferença	b3 (vermelho)
Campo Cerrado e Solo exposto	Média vetor soma	b3 (vermelho)
Campo Cerrado e Área Construída	Média vetor soma	b4 (infraverm. próximo)
Campo limpo e Cerrado	Média vetor soma	b3 (vermelho)
Campo limpo e Fruticultura	Média vetor soma	b4 (infraverm. próximo)
Campo limpo e Horticultura 2	Média vetor soma	b3 (vermelho)
Campo limpo e Horticultura 1	Entropia vetor diferença	b3 (vermelho)
Campo limpo e Mata	Correlação	b4 (infraverm. próximo)
Campo limpo e Reflorestamento	Média vetor soma	b3 (vermelho)
Campo limpo e Solo exposto	Média vetor soma	b3 (vermelho)
Campo limpo e Área Construída	Correlação	b4 (infraverm. próximo)
Cerrado e Fruticultura	Entropia vetor soma	b4 (infraverm. próximo)
Cerrado e Horticultura 2	Entropia vetor soma	b4 (infraverm. próximo)
Cerrado e Horticultura 1	Média vetor soma	b3 (vermelho)
Cerrado e Mata	Entropia vetor diferença	b3 (vermelho)
Cerrado e Reflorestamento	Homogeneidade	b4 (infraverm. próximo)
Cerrado e Solo exposto	Média vetor soma	b3 (vermelho)
Cerrado e Área Construída	Média vetor soma	b4 (infraverm. próximo)
Fruticultura e Horticultura 2	Média vetor soma	b4 (infraverm. próximo)
Fruticultura e Horticultura 1	Homogeneidade	b4 (infraverm. próximo)
Fruticultura e Mata	Entropia vetor soma	b4 (infraverm. próximo)
Fruticultura e Reflorestamento	Entropia	b4 (infraverm. próximo)
Fruticultura e Solo exposto	Média vetor soma	b3 (vermelho)
Fruticultura e Área Construída	Média vetor soma	b3 (vermelho)
Horticultura 2 e Horticultura 1	Média vetor soma	b4 (infraverm. próximo)
Horticultura 2 e Mata	Média vetor soma	b4 (infraverm. próximo)
Horticultura 2 e Reflorestamento	Média vetor soma	b4 (infraverm. próximo)
Horticultura 2 e Solo exposto	Média vetor soma	b3 (vermelho)
Horticultura 2 e Área Construída	Entropia vetor diferença	b3 (vermelho)
Horticultura 1 e Mata	Dissimilaridade	b4 (infraverm. próximo)
Horticultura 1 e Reflorestamento	Média vetor diferença	b4 (infraverm. próximo)
Horticultura 1 e Solo exposto	Média vetor soma	b3 (vermelho)
Horticultura 1 e Área Construída	Entropia vetor diferença	b3 (vermelho)
Mata e Reflorestamento	Chi-quadrado	b4 (infraverm. próximo)
Mata e Solo exposto	Entropia vetor soma	b4 (infraverm. próximo)
Mata e Área Construída	Entropia	b4 (infraverm. próximo)
Reflorestamento e Solo exposto	Média vetor soma	b3 (vermelho)
Reflorestamento e Área Construída	Entropia	b4 (infraverm. próximo)
Solo exposto e Área Construída	Correlação	b4 (infraverm. próximo)

Tabela D.3- Medidas selecionadas para a imagem pancromática do SPOT-5 com 2,5 m de resolução espacial

Par de classes	Medidas de textura
Área Construída e Campo cerrado	Média vetor soma
Área Construída e Campo limpo	Média vetor soma
Área Construída e Cerrado	Correlação
Área Construída e Fruticultura	Média vetor soma
Área Construída e Horticultura 2	Média vetor soma
Área Construída e Horticultura 1	Média vetor soma
Área Construída e Mata	Média vetor soma
Área Construída e Reflorestamento	Média vetor soma
Área Construída e Solo exposto	Entropia vetor diferença
Campo cerrado e Campo limpo	Média vetor soma
Campo cerrado e Cerrado	Média vetor soma
Campo cerrado e Fruticultura	Média vetor soma
Campo cerrado e Horticultura 2	Média vetor soma
Campo cerrado e Horticultura 1	Correlação
Campo cerrado e Mata	Média vetor soma
Campo cerrado e Reflorestamento	Média vetor soma
Campo cerrado e Solo exposto	Média vetor soma
Campo limpo e Cerrado	Energia vetor diferença
Campo limpo e Fruticultura	Energia vetor diferença
Campo limpo e Horticultura 2	Média vetor soma
Campo limpo e Horticultura 1	Média vetor soma
Campo limpo e Mata	Chi-quadrado
Campo limpo e Reflorestamento	Energia vetor diferença
Campo limpo e Solo exposto	Média vetor soma
Cerrado e Fruticultura	Chi-quadrado
Cerrado e Horticultura 2	Média vetor soma
Cerrado e Horticultura 1	Média vetor soma
Cerrado e Mata	Média vetor soma
Cerrado e Reflorestamento	Média vetor soma
Cerrado e Solo exposto	Média vetor soma
Fruticultura e Horticultura 2	Média vetor soma
Fruticultura e Horticultura 1	Média vetor soma
Fruticultura e Mata	Média vetor soma
Fruticultura e Reflorestamento	Média vetor soma
Fruticultura e Solo exposto	Média vetor soma
Horticultura 2e Horticultura 1	Média vetor soma
Horticultura 2e Mata	Média vetor soma
Horticultura 2e Reflorestamento	Média vetor soma
Horticultura 2e Solo exposto	Média vetor soma
Horticultura 1 e Mata	Média vetor soma
Horticultura 1 e Reflorestamento	Média vetor soma
Horticultura 1 e Solo exposto	Média vetor soma
Mata e Reflorestamento	Média vetor soma
Mata e Solo exposto	Média vetor soma
Reflorestamento e Solo exposto	Correlação

Tabela D.4- Medidas selecionadas para a Imagem pancromática do SPOT-5 com 5 m de resolução espacial.

Par de classes	Medidas de textura
Campo Cerrado e Campo limpo	Energia vetor diferença
Campo Cerrado e Cerrado	Média vetor soma
Campo Cerrado e Área Construída	Média vetor soma
Campo Cerrado e Fruticultura	Correlação
Campo Cerrado e Horticultura 2	Média vetor soma
Campo Cerrado e Horticultura 1	Média vetor soma
Campo Cerrado e Mata	Média vetor soma
Campo Cerrado e Reflorestamento	Dissimilaridade
Campo Cerrado e Solo exposto	Média vetor soma
Campo limpo e Cerrado	Entropia vetor diferença
Campo limpo e Área Construída	Média vetor soma
Campo limpo e Fruticultura	Média vetor soma
Campo limpo e Horticultura 2	Energia vetor diferença
Campo limpo e Horticultura 1	Média vetor soma
Campo limpo e Mata	Média vetor soma
Campo limpo e Reflorestamento	Média vetor soma
Campo limpo e Solo exposto	Média vetor soma
Cerrado e Área Construída	Média vetor soma
Cerrado e Fruticultura	Média vetor soma
Cerrado e Horticultura 2	Média vetor soma
Cerrado e Horticultura 1	Média vetor soma
Cerrado e Mata	Média vetor soma
Cerrado e Reflorestamento	Média vetor soma
Cerrado e Solo exposto	Média vetor soma
Área Construída e Fruticultura	Média vetor soma
Área Construída e Horticultura 2	Média vetor soma
Área Construída e Horticultura 1	Média vetor soma
Área Construída e Mata	Média vetor soma
Área Construída e Reflorestamento	Média vetor soma
Área Construída e Solo exposto	Média vetor soma
Fruticultura e Horticultura 2	Média vetor soma
Fruticultura e Horticultura 1	Média vetor soma
Fruticultura e Mata	Média vetor soma
Fruticultura e Reflorestamento	Média vetor soma
Fruticultura e Solo exposto	Média vetor soma
Horticultura 2 e Horticultura 1	Média vetor soma
Horticultura 2 e Mata	Média vetor soma
Horticultura 2 e Reflorestamento	Média vetor soma
Horticultura 2 e Solo exposto	Média vetor soma
Horticultura 1 e Mata	Média vetor soma
Horticultura 1 e Reflorestamento	Média vetor soma
Horticultura 1 e Solo exposto	Entropia
Mata e Reflorestamento	Correlação
Mata e Solo exposto	Média vetor soma
Reflorestamento e Solo exposto	Média vetor soma

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)