

NELSON CARLOS ROSOT

**INTEGRAÇÃO DE IMAGENS DE SENSORES DE MICROONDAS E
ÓPTICOS PARA FINS DE MAPEAMENTO E CLASSIFICAÇÃO DE
REFLORESTAMENTOS NO SUL DO BRASIL**

**Tese apresentada ao Programa de Pós-
Graduação em Engenharia de Produção,
Universidade Federal de Santa Catarina, como
requisito parcial à obtenção do título de Doutor
em Engenharia de Produção.**

Orientador: Prof. Dr. Carlos Loch

FLORIANÓPOLIS

2001

TERMO DE APROVAÇÃO

NELSON CARLOS ROSOT

INTEGRAÇÃO DE IMAGENS DE SENSORES DE MICROONDAS E ÓPTICOS PARA FINS DE MAPEAMENTO E CLASSIFICAÇÃO DE REFLORESTAMENTOS NO SUL DO BRASIL

Esta tese foi julgada adequada para a obtenção do título de DOUTOR EM ENGENHARIA DE PRODUÇÃO e aprovada em sua forma final pelo Programa de Pós-Graduação da Universidade Federal de Santa Catarina.

Prof. Ricardo Miranda Barcia, Ph.D
Coordenador do Curso

Banca Examinadora:

Pesq. Yeda M. Malheiros de Oliveira, Ph. D
Membro – EMBRAPA

Prof. Attilio Antonio Disperati, PhD
Membro – UNICENTRO

Prof. Dr. Czeslau L. Barczak
Membro – UFSC

Prof. Dr. Ing. Jürgen Philips
Membro e Moderador – UFSC

Prof. Dr. Carlos Loch
Orientador – UFSC

Florianópolis, 7 de dezembro de 2001

À minha esposa, Maria Augusta
Às minhas filhas, Maria Júlia, Thaís Carolina e Luciana Theresa
E à memória de meus pais, Aleixo e Rosalina

Dedico

AGRADECIMENTOS

Ao Departamento de Ciências Florestais da Universidade Federal do Paraná (UFPR), que possibilitou a realização do curso e aprimoramento técnico-científico.

À Coordenação de Aperfeiçoamento de Pessoal de Ensino Superior (CAPES), pelo suporte financeiro durante o curso.

Ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Santa Catarina, pelo aceite no Programa de Doutorado.

Ao Professor Dr. Osmar Possamai, pelo aceite na condição de orientador na fase inicial deste curso.

Ao Professor Dr. Carlos Loch, pelas contribuições e incentivos na orientação deste trabalho.

À Agência Nacional de Desenvolvimento Espacial do Japão (NASDA), pela doação da imagem de radar (JERS-1-SAR).

À Pisa Florestal, por ter gentilmente disponibilizado o cadastro florestal e prestado apoio na fase de definição do projeto.

À Engefoto – Engenharia e Aerolevantamentos S.A., pela doação das fotografias aéreas.

À minha esposa, Maria Augusta Doetzer Rosot, pelo companheirismo, compreensão, incentivo e ajuda durante todas as fases deste trabalho.

Ao Professor Dr. Dartagnan Baggio Emerenciano, da Comissão Central do Concurso Vestibular (CCCV) da Universidade Federal do Paraná, pela amizade, apoio e incentivo nas diferentes fases deste curso.

Ao Dr. Waldir Paradella, do Instituto Nacional de Pesquisas Espaciais (INPE), pelo apoio na fase de ortoretificação da imagem JERS.

Ao Professor Stélio Tavares Junior, do Departamento de Geociências da Universidade Federal de Roraima (UFRR), pelo apoio técnico-científico dispensado na ortoretificação, junto ao Laboratório de Tratamento de Imagens Digitais (LTID) do INPE.

À pesquisadora Dra. Yeda M.M. de Oliveira, do CNPF – EMBRAPA, por sua amizade e pelas valiosas contribuições durante a fase do processamento digital de imagens.

Aos amigos Moacir Marcolin, Elizabeth Wegner Karas, Sérgio Zampieri, Luiz Fernando Figueiredo, Hermés Oliveira dos Anjos e Weimar Freire da Rocha Jr pelo convívio, amizade e incentivo durante a realização do curso.

SUMÁRIO

LISTA DE TABELAS	viii
LISTA DE FIGURAS	x
LISTA DE SIGLAS	xiii
RESUMO	xvi
ABSTRACT	xvii
1 INTRODUÇÃO	1
1.1 OBJETIVOS	4
1.1.1 Objetivo Geral.....	4
1.1.2 Objetivos Específicos	4
2 REVISÃO DE LITERATURA	5
2.1 SENSORIAMENTO REMOTO E A ENERGIA ELETROMAGNÉTICA	5
2.2 IMAGENS DIGITAIS	7
2.3 SISTEMAS SENSORES	8
2.3.1 Sensores Eletro-Ópticos de Varredura (<i>scanners</i>)	9
2.3.1.1 Sistema LANDSAT 5	10
2.3.2 Comportamento Espectral de Alvos em Relação aos Sensores Ópticos	11
2.3.2.1 Água	13
2.3.2.2 Solo	14
2.3.2.3 Vegetação	16
2.3.3 Sensores de Microondas	20
2.3.3.1 Radar de visada lateral (SLAR)	22
2.3.3.1.1 Sistema radar de abertura real (RAR)	23
2.3.3.1.2 Sistema radar de abertura sintética (SAR)	24
2.3.3.2 Geometria de um radar imageador	28
2.3.3.3 Resolução	31
2.3.3.3.1 Resolução azimutal	32
2.3.3.3.2 Resolução transversal ou resolução espacial	33
2.3.3.4 Fatores que afetam os sinais de retorno do radar	33
2.3.3.4.1 Relevo e ângulo de depressão	34
2.3.3.4.2 Rugosidade	36
2.3.3.4.3 Permittividade	37
2.3.3.4.4 Polarização	38
2.3.3.4.5 Direção de visada da antena e orientação das feições	39
2.3.3.5 Penetração dos sinais de radar	40
2.3.3.5.1 Penetração dos sinais em relação à água	41
2.3.3.5.2 Penetração dos sinais em relação ao solo	42
2.3.3.5.3 Penetração dos sinais em relação à vegetação	43
2.3.3.6 Ruído (<i>Speckle</i>)	45
2.3.3.7 Sistemas radares orbitais	49
2.3.3.7.1 Sistema JERS	50
2.4 PROCESSAMENTO DIGITAL DE IMAGENS	52
2.4.1 Pré-Processamento ou Restauração de Imagens	52

2.4.1.1 Correção radiométrica	52
2.4.1.2 Correção geométrica	53
2.4.2 Realce de Imagens	56
2.4.2.1 Realce de contraste	56
2.4.2.2 Processamento de características espaciais	57
2.4.2.3 Processamento multi-imagem	59
2.4.3 Fusão de Dados	64
2.4.3.1 Fusão de imagens dos sensores LANDSAT TM e SAR	64
2.4.4 Classificação de Imagens	70
2.4.4.1 Treinamento não-supervisionado	71
2.4.4.2 Treinamento supervisionado	72
2.4.4.3 Treinamento híbrido	73
2.4.4.4 Assinaturas espectrais	74
2.4.4.5 Algoritmos paramétricos de classificação	75
2.4.4.6 Algoritmos não-paramétricos de classificação	79
2.4.4.7 Segmentação espacial-espectral	81
2.4.5 Acuracidade Temática	82
2.5 A UTILIZAÇÃO DE IMAGENS DE SATÉLITES NO MAPEAMENTO E CLASSIFICAÇÃO FLORESTAL	85
2.5.1 Imagens de Radar	85
2.5.2 Imagens Ópticas	90
2.5.3 Imagens Combinadas	92
3 MATERIAL E MÉTODOS	96
3.1 DESCRIÇÃO DA ÁREA DE ESTUDO	96
3.1.1 Clima	96
3.1.2 Geologia e Geomorfologia	97
3.1.3 Vegetação	97
3.1.4 Reflorestamentos	98
3.2 MATERIAL.....	99
3.2.1 Imagens de Satélites	99
3.2.1.1 Imagem JERS	99
3.2.1.2 Imagens LANDSAT-5 TM	99
3.2.2 Dados Auxiliares para Controle de Campo	100
3.2.3 Equipamentos e Programas	101
3.2.3.1 Equipamentos	101
3.2.3.2 Programas	101
3.3 MÉTODO	101
3.3.1 Imagem JERS.....	102
3.3.1.1 Pré-Processamento	102
3.3.1.1.1 Correções geométricas.....	103
3.3.1.1.2 Ortorectificação.....	105
3.3.1.2 Processamento	109
3.3.1.2.1 Segmentação.....	109
3.3.1.2.2 Classificação não-supervisionada.....	109
3.3.1.2.3 Classificação supervisionada.....	110

3.3.1.2.4 Avaliação da acuracidade temática.....	110
3.3.1.2.5 Conversão via tela.....	110
3.3.2 Imagens LANDSAT-5 TM	113
3.3.2.1 Pré-processamento	113
3.3.2.1.1 Recorte da área.....	113
3.3.2.1.2 Correção atmosférica.....	113
3.3.2.1.3 Correção geométrica.....	114
3.3.2.2 Processamento	115
3.3.3 Fusão de Imagens	116
4 RESULTADOS E DISCUSSÃO	118
4.1 IMAGEM JERS1-SAR.....	118
4.1.1 Pré-processamento.....	118
4.1.1.1 Correções radiométricas e geométricas	118
4.1.1.2 Ortoretificação.....	119
4.1.2 Processamento.....	123
4.1.2.1 Segmentação de imagens.....	123
4.1.2.2 Classificação não-supervisionada.....	125
4.1.2.3 Classificação supervisionada.....	128
4.1.2.4 Acurácia temática	129
4.1.2.5 Geração do mapa temático	132
4.1.2.6 Estimativa de áreas de talhões	135
4.2 IMAGENS LANDSAT-5 TM.....	138
4.2.1 Recorte da Imagem.....	138
4.2.2 Correção Atmosférica.....	138
4.2.3 Correções Geométricas.....	138
4.2.4 Realce de Contraste.....	139
4.2.5 Composições Coloridas RGB.....	139
4.2.6 Transformações de Dados.....	140
4.2.7 Segmentação de Imagens	143
4.2.8 Classificação Temática	144
4.2.8.1 Classificação não-supervisionada.....	144
4.2.8.2 Classificação supervisionada.....	145
4.2.8.3 Acurácia temática	145
4.3 FUSÃO DE IMAGENS LANDSAT-5 TM E JERS1-SAR.....	148
4.3.1 Registro de Imagens.....	148
4.3.2 Técnicas de Fusão de Imagens.....	148
4.3.2.1 Combinação simples de bandas.....	148
4.3.2.2 Componentes principais.....	149
4.3.2.3 Transformação IHS	156
4.3.3 Segmentação de Imagens.....	162
4.3.4 Classificação Temática.....	164
4.3.4.1 Acurácia temática.....	164
5 CONCLUSÕES E RECOMENDAÇÕES	168
REFERÊNCIAS BIBLIOGRÁFICAS	171
APÊNDICES.....	188

LISTA DE TABELAS

TABELA 1	- BANDAS ESPECTRAIS DO SENSOR THEMATIC MAPPER DO SATÉLITE LANDSAT 5	11
TABELA 2	- DESIGNAÇÃO DE BANDAS, COMPRIMENTOS DE ONDA E FREQUÊNCIAS DE RADAR.....	22
TABELA 3	- CLASSES DE FEIÇÕES E AMPLITUDES TONAIIS REPRESENTATIVAS EM IMAGENS SLAR	35
TABELA 4	- CARACTERÍSTICAS DAS MISSÕES DE RADAR TRANSPORTADO NO ÔNIBUS ESPACIAL	50
TABELA 5	- CARACTERÍSTICAS DOS PRINCIPAIS SISTEMAS RADARES ORBITAIS	51
TABELA 6	- CARACTERÍSTICAS DO PRODUTO JERS-1 NÍVEL 2.1.....	102
TABELA 7	- PONTOS DE CONTROLE (GCPs) EMPREGADOS NO AJUSTE DO MODELO DO SATÉLITE.....	121
TABELA 8	- MATRIZ DE ERROS DA CLASSIFICAÇÃO SUPERVISIONADA DA IMAGEM JERS1-SAR	131
TABELA 9	- ACURÁCIAS DO PRODUTOR E DO USUÁRIO POR CLASSE	132
TABELA 10	- MATRIZ DE CORRELAÇÃO DAS SEIS BANDAS TM	141
TABELA 11	- COEFICIENTES DAS VARIÁVEIS DAS COMPONENTES PRINCIPAIS (MATRIZ DOS AUTO-VETORES TRANSPOSTOS) E AUTO-VALORES, COM BASE NA MATRIZ DE COVARIÂNCIA (BANDAS 1,2,3,4,5 E 7)	141
TABELA 12	- COEFICIENTES DAS VARIÁVEIS DAS COMPONENTES PRINCIPAIS (MATRIZ DOS AUTO-VETORES TRANSPOSTOS) E AUTO-VALORES, COM BASE NA MATRIZ DE COVARIÂNCIA (BANDAS 3,4,5).....	143
TABELA 13	- COEFICIENTES DAS VARIÁVEIS DAS COMPONENTES PRINCIPAIS (MATRIZ DOS AUTO-VETORES TRANSPOSTOS) E AUTO-VALORES, COM BASE NA MATRIZ DE COVARIÂNCIA (BANDAS 4,5 E 7)	143
TABELA 14	- MATRIZ DE ERROS DA CLASSIFICAÇÃO SUPERVISIONADA DA IMAGEM LANDSAT-5 TM	147
TABELA 15	- ACURÁCIAS DO PRODUTOR E DO USUÁRIO POR CLASSE	147
TABELA 16	- SENSORES E BANDAS ENVOLVIDOS NA TRANSFORMAÇÃO POR COMPONENTES PRINCIPAIS PARA A FUSÃO DE DADOS ÓPTICOS E DE RADAR.....	151
TABELA 17	- MATRIZ DE CORRELAÇÃO ENTRE AS SEIS BANDAS TM E JERS	153

TABELA 18	-	COEFICIENTES DAS VARIÁVEIS DAS COMPONENTES PRINCIPAIS (MATRIZ DOS AUTO-VETORES TRANSPOSTOS) E AUTO-VALORES, COM BASE NA MATRIZ DE CORRELAÇÃO (BANDAS TM 1,2,3,4,5, 7 E JERS)	154
TABELA 19	-	COEFICIENTES DAS VARIÁVEIS DAS COMPONENTES PRINCIPAIS (MATRIZ DOS AUTO-VETORES TRANSPOSTOS) E AUTO-VALORES, COM BASE NA MATRIZ DE CORRELAÇÃO (BANDAS TM 3,4,5 E JERS)	154
TABELA 20	-	COEFICIENTES DAS VARIÁVEIS DAS COMPONENTES PRINCIPAIS (MATRIZ DOS AUTO-VETORES TRANSPOSTOS) E AUTO-VALORES, COM BASE NA MATRIZ DE CORRELAÇÃO (BANDAS TM 4,5, 7 E JERS)	154
TABELA 21	-	MATRIZ DE ERROS DA CLASSIFICAÇÃO SUPERVISIONADA DA IMAGEM HÍBRIDA LANDSAT-5 TM + JERS1-SAR	166
TABELA 22	-	ACURÁCIAS DO PRODUTOR E DO USUÁRIO POR CLASSE	167

LISTA DE FIGURAS

FIGURA 1	- PRINCIPAIS REGIÕES ESPECTRAIS, BANDAS DE ABSORÇÃO (EM PRETO) E JANELAS ATMOSFÉRICAS....	6
FIGURA 2	- COMPORTAMENTO ESPECTRAL TÍPICO DA VEGETAÇÃO SADIA	17
FIGURA 3	- CURVAS DE REFLECTÂNCIA ESPECTRAL PARA DECÍDUAS (FOLHOSAS) E CONÍFERAS	18
FIGURA 4	- COMPORTAMENTO ESPECTRAL DA VEGETAÇÃO, SOLO E ÁGUA	20
FIGURA 5	- DIAGRAMA DE OPERAÇÃO DE UMA ANTENA SINTÉTICA	25
FIGURA 6	- FATORES DETERMINANTES DA RESOLUÇÃO NO RADAR DE ABERTURA SINTÉTICA	26
FIGURA 7	- ESQUEMA DE FUNCIONAMENTO DE ANTENA SINTÉTICA COM 4 LOOKS	27
FIGURA 8	- CARACTERÍSTICAS GEOMÉTRICAS DO SLAR	29
FIGURA 9	- REFLEXÃO DOS SINAIS DE RADAR PARA VÁRIAS SUPERFÍCIES	36
FIGURA 10	- INFLUÊNCIA DO TEOR DE UMIDADE DO SOLO NO COEFICIENTE DE RETROESPALHAMENTO	43
FIGURA 11	- PENETRAÇÃO DA RADIAÇÃO RADAR NA VEGETAÇÃO, EM FUNÇÃO DO ÂNGULO DE INCIDÊNCIA EM DIFERENTES COMPRIMENTOS DE ONDA	45
FIGURA 12	- AMPLIAÇÃO LINEAR DE CONTRASTE	58
FIGURA 13	- FREQUÊNCIAS ESPACIAIS	58
FIGURA 14	- ESFERA DAS CORES NO SISTEMA IHS	63
FIGURA 15	- LOCALIZAÇÃO DA ÁREA DE ESTUDO NO BRASIL E NO ESTADO DO PARANÁ	96
FIGURA 16	- ARQUIVO DE ALTIMETRIA DA ÁREA DE ESTUDO	107
FIGURA 17	- ARQUIVO VETORIAL CONTENDO LIMITES DOS TALHÕES, ESTRADAS E ACEIROS DE PARTE DA ÁREA DE ESTUDO	111
FIGURA 18	- SUB-CENA DA IMAGEM JERS1-SAR FILTRADA (FILTRO DE FROST, 5 X 5), CONTENDO A ÁREA DE ESTUDO	119
FIGURA 19	- MAPA HIPSOMÉTRICO DE PARTE DA FAZENDA MOCAMBO, CONTENDO A ÁREA DE ESTUDO.....	120
FIGURA 20	- IMAGEM JERS1-SAR, ORTORRETIFICADA, CONTENDO A ÁREA DE ESTUDO E PONTOS DE CONTROLE (GCPs)..	122

FIGURA 21	- (a) IMAGEM JERS1-SAR SEGMENTADA, COM LIMIAR DE SIMILARIDADE 20 E LIMIAR DE ÁREA IGUAL A 30; (b) AMPLIAÇÃO DE TALHÕES DE <i>Eucalyptus spp</i>	124
FIGURA 22	- CLASSIFICAÇÃO NÃO-SUPERVISIONADA DA IMAGEM JERS1-SAR (ALGORITMO ISODATA)	126
FIGURA 23	- CLASSIFICAÇÃO NÃO-SUPERVISIONADA DA IMAGEM JERS1-SAR SEGMENTADA (ALGORITMO ISOSEG)	128
FIGURA 24	- CLASSIFICAÇÃO SUPERVISIONADA DA IMAGEM JERS1-SAR SEGMENTADA (ALGORITMO BHATTACHARYYA)	130
FIGURA 25	- MAPA DE VEGETAÇÃO DA ÁREA DE ESTUDO ELABORADO A PARTIR DE SEGMENTAÇÃO E INTERPRETAÇÃO VISUAL DA IMAGEM JERS1-SAR	134
FIGURA 26	- TALHÕES-AMOSTRA VETORIZADOS SOBRE A IMAGEM JERS1-SAR	135
FIGURA 27	- SEGUNDA COMPONENTE PRINCIPAL (CPa2) DAS BANDAS LANDSAT TM 1-5 E 7.....	142
FIGURA 28	- MAPA DE VEGETAÇÃO DA ÁREA DE ESTUDO ELABORADO A PARTIR DE CLASSIFICAÇÃO SUPERVISIONADA DA IMAGEM LANDSAT-5 TM	146
FIGURA 29	- COMPOSIÇÃO COLORIDA EM RGB (R-TM5; G-TM4; B-JERS)	150
FIGURA 30	- COMPOSIÇÃO COLORIDA DA IMAGEM JERS E DAS COMPONENTES PRINCIPAIS DE TODAS AS BANDAS LANDSAT TM (R-CPa5; G-CPa2; B-JERS)	152
FIGURA 31	- COMPOSIÇÃO COLORIDA DAS COMPONENTES PRINCIPAIS INCLUINDO AS BANDAS LANDSAT TM4, TM5, TM7 E JERS (R-CPf1; G-CPf4; B-CPf3)	155
FIGURA 32	- INTEGRAÇÃO DAS COMPONENTES PRINCIPAIS (CPb1, CPb2, CPb3) LANDSAT TM E JERS POR TRANSFORMAÇÃO IHS (DETALHE DA ÁREA DE ESTUDO)	156
FIGURA 33	- INTEGRAÇÃO DE IMAGENS LANDSAT TM (BANDAS TM3, TM4, TM5) E JERS POR TRANSFORMAÇÃO IHS (a, b - DETALHES DA ÁREA DE ESTUDO)	157
FIGURA 34	- INTEGRAÇÃO DE IMAGENS LANDSAT (TM5, CPa2, NDVI) E JERS POR TRANSFORMAÇÃO IHS. DETALHE AMPLIADO DA ÁREA DE ESTUDO)	158
FIGURA 35	- INTEGRAÇÃO DE IMAGENS LANDSAT TM (BANDAS TM3, TM4, TM5) E JERS POR TRANSFORMAÇÃO IHS, DESCARTANDO-SE O CANAL "MATIZ (H)". (a, b - DETALHES DA ÁREA DE ESTUDO)	159

FIGURA 36 - INTEGRAÇÃO DE IMAGENS LANDSAT TM (BANDAS TM3, TM4, TM5) E JERS POR TRANSFORMAÇÃO IHS, DESCARTANDO-SE O CANAL "MATIZ (H)". DETALHE DA ÁREA DE ESTUDO	160
FIGURA 37 - COMPOSIÇÃO COLORIDA RESULTANTE DA TRANSFORMAÇÃO IHS (R-RETRANSFORMADA DA TM4, G-RETRANSFORMADA DA JERS, B-RETRANSFORMADA DA CPd1)	161
FIGURA 38 - IMAGEM HÍBRIDA EM COMPOSIÇÃO COLORIDA RGB (CPa5, CPa2, JERS) SEGMENTADA. DETALHE DA ÁREA DE ESTUDO	163
FIGURA 39 - MAPA DE VEGETAÇÃO DA ÁREA DE ESTUDO ELABORADO A PARTIR DE CLASSIFICAÇÃO SUPERVISIONADA DA IMAGEM HÍBRIDA "LANDSAT-5 TM / JERS1-SAR".....	165

LISTA DE SIGLAS

ADEOS – *Advanced Earth Observing Satellite*
ALOS – *Advanced Land Observing Satellite*
ASPRS – *American Society for Photogrammetry and Remote Sensing*
AVHRR – *Advanced Very High Resolution Radiometer*
BSQ – *Band Sequential Format*
BIL – *Band Interleaved by Line*
CASI – *Compact Airborne Spectral Imager*
CCD – *Charge-Coupled Device*
CCRS – *Canadian Centre for Remote Sensing*
CEOS – *Committee of Earth Observation Satellites*
DEM – *Digital Elevation Model*
DN – *Digital number*
DSG – *Diretoria de Serviço Geográfico*
DXF – *Drawing eXchange File*
ENVI – *Environment for Visualizing Images*
EORC – *Earth Observation Research Center*
ERDAS – *Earth Resource Data Analysis System*
ERS – *European Remote Sensing Satellite*
ESA – *European Space Agency*
ETM – *Enhanced Thematic Mapper*
GCP – *Ground Control Point*
GEOS – *GEOcoding System*
GEMS – *Goodyear Electronic Mapping System*
GIF – *Graphics Interchange Format*
GIS – *Geographic Information System*
GPS – *Global Positioning System*
GRFM – *Global Rainforest Monitoring*

HDOP – *Horizontal Dilution of Precision*
HH – *Horizontal transmission and Horizontal reception*
HRV – *Haute Résolution Visible*
IAF – *Índice de Área Foliar*
ICM – *Interactive Conditional Modes*
IFOV – *Instantaneous Field Of View*
IHS – *Intensity Hue Saturation*
InSAR – *Interferometric SAR*
ISPRS – *International Society for Photogrammetry and Remote Sensing*
IV – *Infravermelho*
JERS – *Japanese Earth Resources Satellite*
JPEG – *Joint Photographic Experts Group*
JPL – *Jet Propulsion Laboratory*
LANDSAT – *Land Observation Satellite*
MSS – *Multispectral Scanner*
NASDA – *National Space Development Agency of Japan*
NOAA – *National Oceanic and Atmospheric Administration*
PALSAR – *Phased Array type L – band Synthetic Aperture Radar*
PAN – *Panchromatic*
PCA – *Principal Component Analysis*
PRISM – *Panchromatic Remote-sensing Instrument for Stereo Mapping*
RADAR – *Radio Detection and Ranging*
RAR – *Real Aperture Radar*
RBV – *Return Beam Vidicon*
REM – *Radiação eletromagnética*
RESTEC – *Remote Sensing Technology Center of Japan*
RGB – *Red Green Blue*
RMS – *Root Mean Square*
RMSE – *Root Mean Square Error*
RS – *Remote Sensing*

RSI – RadarSat International
SAR – Synthetic Aperture Radar
SIR – Shuttle Imaging Radar
SLAR – Side-looking Airborne Radar
SMODEL – Satellite Model
SPOT – Système Pour l’Observation de la Terre
SPRING – Sistema de Processamento de Informações Georreferenciadas
SRORTHO – Satellite Radar Orthorectification
STRM – Shuttle Radar Topography Mission
TIFF – Tagged Image File Format
TM – Thematic Mapper
TMS – Thematic Mapper Simulator
UTM – Universal Transverse Mercator
VIR – Visible and near InfraRed
VV – Vertical transmission and Vertical reception
WGS’84 – World Geodetic System from 1984
XS – Multispectral

RESUMO

O presente trabalho teve por objetivo avaliar as potencialidades de sensores ópticos e de microondas para a elaboração de mapas temáticos e classificação de reflorestamentos no município de Sengés, Estado do Paraná. Foram utilizadas imagens dos sensores JERS1-SAR e LANDSAT-5 TM, ambas de dezembro de 1995. A área de estudo, equivalente a aproximadamente 5000 ha, é constituída por povoamentos de *Eucalyptus spp* e *Pinus spp*, com diversas idades e submetidos a diferentes regimes de manejo. Foram efetuadas três abordagens distintas analisando o desempenho de técnicas de processamento digital de imagens na classificação e elaboração de mapas de vegetação dessas áreas, a partir de imagens dos sensores de microondas e ópticos, isoladamente e, depois, dos produtos de sua fusão. A imagem de radar foi ortorretificada considerando-se as informações obtidas do modelo do satélite e do modelo digital do terreno (DEM). A imagem LANDSAT TM foi corrigida geometricamente empregando-se transformações polinomiais. Para o registro entre as duas imagens foi empregada a técnica “mestre-escravo”, adotando-se como referência a imagem de radar ortorretificada. Entre os processos de fusão aplicados incluíram-se a combinação simples de bandas dos dois sensores, a transformação estatística por componentes principais e a transformação IHS. Nesta pesquisa a combinação simples de bandas envolvendo a imagem de radar e as componentes principais da imagem LANDSAT foi considerada a melhor técnica para a fusão de imagens. Embora a transformação IHS não tenha produzido os resultados esperados, alguns dos produtos híbridos obtidos por esta técnica foram úteis na discriminação de alvos pontuais, tais como talhões cortados em diferentes épocas, talhões de diferentes idades e espécies do gênero *Pinus* e áreas com gramíneas e mata nativa. A segmentação de imagens revelou-se bastante promissora com relação ao processamento de imagens JERS, sendo que o mapa temático foi elaborado a partir de um procedimento combinado envolvendo a atribuição de classes temáticas aos polígonos gerados pela segmentação. Na classificação temática o algoritmo de Bhattacharyya produziu os melhores resultados em todas as abordagens, indistintamente. Verificou-se um aumento da acurácia temática com a integração das imagens ópticas e de radar, tendo-se obtido valores de acurácia geral iguais a 60,19%, 73,30% e 82,53% para as classificações efetuadas sobre a imagem JERS1-SAR, LANDSAT-5 TM e híbrida, respectivamente.

Palavras-chave: sensoriamento remoto, sensores de microondas, fusão de imagens

ABSTRACT

The present study was conducted to assess the potential of optical and microwave sensors to the mapping and classification of forest plantations in Sengés, Paraná State. Imagery from December 1995 were acquired, for both JERS1-SAR and LANDSAT-5 TM. The study area covers approximately 5,000 ha of *Eucalyptus spp* and *Pinus spp* stands from different ages and under different management practices. Three approaches were taken in order to evaluate the performance of digital image processing techniques in classification and vegetation mapping, firstly using imagery from each sensor separately and then the hybrid imagery resulting from fusion of the two data sets. A digital elevation model was generated for correction of terrain-related geometric distortions in radar imagery, while for LANDSAT-5 TM imagery rectification, a simple first-order polynomial transformation was found to be adequate. The TM data were coregistered to the SAR orthorectified image using a “master-slave” procedure. Image processing techniques for data fusion included band combinations, statistical transforms and colour space transforms (IHS). The best results were achieved through band combinations of SAR imagery and the principal components of TM imagery. Although IHS transforms have not provided the expected results, some hybrid products generated by this technique helped in the discrimination of specific targets like stands that were clearcut in different times, *Pinus* stands of different ages and different species, as well as grass and native forest. The image segmentation technique was considered one of the most promising approaches in radar imagery processing. A vegetation map was created by assigning classes to the polygons generated by segmentation. The Bhattacharyya algorithm yielded the best results over the three tested approaches. Improved thematic overall accuracies were observed for fused imagery (82.53%) against the 60.19% and 73.30% obtained respectively, for classification schemes based on the independent JERS-1 SAR and LANDSAT-5 TM imagery.

Keywords: remote sensing, microwave sensors, image fusion

INTRODUÇÃO

O desenvolvimento florestal no Brasil ganhou grande impulso a partir de 1967 com a lei dos incentivos fiscais, quando extensos maciços florestais foram implantados em diferentes partes do país.

No sul do Brasil, devido ao clima subtropical predominante, houve uma tendência pelo reflorestamento com espécies de clima temperado, principalmente *Pinus elliottii* Engelm. e *Pinus taeda* L., que apresentaram melhores condições de adaptação, crescimento e produção. A preferência recaiu pelo gênero *Pinus* devido à necessidade de produzir madeira de fibra longa para atender à grande demanda de madeira serrada e, principalmente, abastecer com matéria-prima as indústrias de papel e celulose instaladas na região, preservando, com isso, parte das florestas nativas de *Araucaria angustifolia* (Bert.) O. Ktze ainda existentes.

Foram também utilizadas espécies do gênero *Eucalyptus* para suprir a demanda de madeira para fins energéticos. A *Araucaria angustifolia* teve pequena participação nos reflorestamentos devido a seu crescimento mais lento quando comparado ao das espécies de coníferas exóticas (DE HOOGH, 1978; CRECHI, 1996).

O Estado do Paraná, segundo dados de 1998 (SILVA, 2000), detém 14,31% dos reflorestamentos de *Pinus spp* e *Eucalyptus spp* efetuados no Brasil, ocupando o primeiro lugar em reflorestamentos de *Pinus spp* (609.683 ha) e o 5º. lugar em *Eucalyptus spp* (56.038 ha).

O distrito florestal compreendido pelos municípios de Sengés, Jaguariaíva e Piraí do Sul contribui com um grande percentual deste total plantado – quase que exclusivamente com *Pinus spp* – para abastecer as indústrias de papel e celulose concentradas nessa região. Estas florestas estão sendo manejadas de forma bastante intensa, quer para produção de madeira serrada, quer para produção de celulose e papel. Com a globalização do mercado as empresas estão se tornando mais competitivas, visando produzir madeira de melhor qualidade e com menores custos de produção. O mercado consumidor – principalmente o europeu – exige produtos com

certificado de procedência, o que tem levado as empresas florestais a se habilitar ao processo de certificação florestal. Este envolve uma série de condicionantes, tanto para emissão como para a manutenção dos certificados, incluindo-se entre elas a disponibilização de informações e mapas atualizados das florestas a qualquer tempo e em diferentes níveis de precisão e detalhamento.

Devido aos altos custos, poucas empresas possuem condições de efetuar levantamentos aerofotogramétricos periódicos para atualizar os seus mapas florestais. Sensores orbitais ópticos – especialmente o LANDSAT TM – constituem uma alternativa viável e largamente utilizada no Brasil para o monitoramento de florestas desde a década de 70. No entanto as imagens LANDSAT nem sempre apresentam boa qualidade devido à presença constante de nuvens na atmosfera, que produzem áreas sem informação, quer pelas nuvens propriamente ditas, quer pela sombra causada por essas nuvens (SOARES et al., 1997). Os sensores radares orbitais vêm preencher esta lacuna, pois o processo de obtenção de imagens de microondas independe das condições climáticas e, conforme a frequência do pulso de radar emitido, as nuvens se tornam praticamente transparentes para as microondas (PALME, 1997).

A grande maioria das pesquisas até então efetuadas com sensores de microondas no Brasil tem se concentrado no monitoramento e classificação de florestas nativas, especialmente na Região Amazônica (DUTRA et al., 1999; SHIMABUKURO et al., 1998; SCALES et al., 1997; SCHMIDT et al., 1997).

Com relação às florestas plantadas, AHERN et al. (1993b) consideram que os sistemas radares orbitais não são capazes de proporcionar ganho significativo de informações no que diz respeito à composição de espécies (tipologia florestal) ou quanto ao volume utilizável de madeira. No entanto, sugerem que sistemas de microondas que operam com ondas mais longas sejam investigados mais detalhadamente quanto ao seu potencial para aplicações florestais. Isto se deve ao fato de que as ondas emitidas por esses sistemas possuem maior penetração no dossel, fornecendo melhor resposta quanto à densidade e biomassa dos povoamentos florestais.

O único radar com comprimento de onda longo (banda L - 23,5 cm) em plataforma satelitária foi o sensor JERS-1 SAR, que operou até 11 de outubro de 1998. As imagens históricas arquivadas em bancos de dados encontram-se disponíveis para trabalhos de pesquisa e/ou aplicações comerciais.

Devido à natureza das imagens de radar – onde são enfatizadas as propriedades físicas e elétricas dos alvos – nem sempre serão obtidos os resultados esperados em termos de classificação. É de se supor que a fusão de imagens de sensores radares e ópticos – em que as propriedades químicas dos objetos se manifestam nas variações tonais – possa contribuir significativamente na discriminação das diferentes espécies usadas em reflorestamentos, gerando classificações mais acuradas em comparação aos resultados obtidos quando se utiliza cada sensor isoladamente.

O desenvolvimento de uma metodologia para tornar mais prático o uso de imagens de radar, isoladamente ou combinadas com imagens LANDSAT, justifica-se pelo fato de ser esta uma forma mais rápida para mapear ou atualizar mapas de reflorestamento na região sul do Brasil em comparação aos levantamentos aerofotogramétricos tradicionais.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Avaliar as potencialidades da imagem JERS e a sua integração com imagens LANDSAT-5 TM para a elaboração de mapas temáticos e classificação de reflorestamentos de *Eucalyptus spp* e *Pinus spp* em área localizada no município de Sengés, Estado do Paraná.

1.1.2 Objetivos Específicos

- a) Analisar o desempenho de técnicas de processamento digital de imagens na classificação e elaboração de mapas de áreas florestais a partir de imagens de sensores de microondas (JERS1-SAR);
- b) Avaliar o método de conversão via tela para a obtenção de estimativas de áreas de talhões a partir da interpretação visual da imagem JERS1-SAR;
- c) Analisar o desempenho de técnicas de processamento digital de imagens na classificação e elaboração de mapas de áreas florestais a partir de imagens de sensores ópticos (LANDSAT-5 TM);
- d) Testar e analisar diferentes técnicas de fusão de imagens de sensores de microondas (JERS1-SAR) e ópticos (LANDSAT-5 TM), visando a classificação e elaboração de mapas de áreas florestais a partir de imagens híbridas;
- e) Comparar a acurácia temática dos mapas gerados com as imagens JERS1-SAR, LANDSAT-5 TM e híbridas.

2 REVISÃO DE LITERATURA

2.1 SENSORIAMENTO REMOTO E A ENERGIA ELETROMAGNÉTICA

Sensoriamento Remoto é uma técnica de obtenção de informações sobre um objeto, área ou fenômeno através da análise de dados adquiridos à distância, por instrumentos que não estão em contato com o objeto, área ou fenômeno em estudo (LANDGREBE, 1978; ROUGHGARDEN et al., 1991; LILLESAND e KIEFER, 1994). Tais instrumentos são conhecidos coletivamente como sensores remotos e incluem câmeras fotográficas, *scanners* mecânicos e sistemas radares, tanto aerotransportados quanto orbitais.

A energia tradicionalmente medida em sensoriamento remoto é a radiação eletromagnética (REM), incluindo a luz visível, que é refletida ou emitida em vários níveis por todos os objetos naturais e sintéticos (AVERY e BERLIN, 1992). A energia eletromagnética é gerada por vários mecanismos, incluindo alterações nos níveis de energia dos elétrons, aceleração de cargas elétricas, decomposição de substâncias radioativas e movimentação termal de átomos e moléculas (CAMPBELL, 1996). A radiação eletromagnética consiste de um campo elétrico que varia em magnitude numa direção perpendicular à direção de propagação. Além disso, um campo magnético, orientado em ângulos retos ao campo elétrico, é propagado em fase com o campo elétrico.

São três as propriedades apresentadas pela energia eletromagnética:

- a) comprimento de onda: é a distância da crista de uma onda à próxima;
- b) frequência: é o número de cristas passando por um ponto fixo num dado período;
- c) amplitude: é a altura de cada pico.

Assim, características da energia eletromagnética podem ser especificadas usando tanto a frequência como o comprimento de onda, sendo este último prática comum no campo do sensoriamento remoto para definir regiões do espectro

eletromagnético (CAMPBELL, 1996). As unidades mais freqüentemente empregadas são o micrômetro (μm), equivalente a 10^{-6} m, o milímetro, o centímetro e o metro.

As divisões do espectro eletromagnético são arbitrariamente definidas, de acordo com o campo do conhecimento onde são aplicadas. Na Figura 1 são apresentadas as principais regiões espectrais do sensoriamento remoto, bem como as janelas atmosféricas, os gases responsáveis pela absorção e a amplitude operacional dos sistemas de sensoriamento remoto mais comuns. As janelas atmosféricas referem-se às faixas de comprimento de onda que são facilmente transmitidas através da atmosfera (CAMPBELL, 1996).

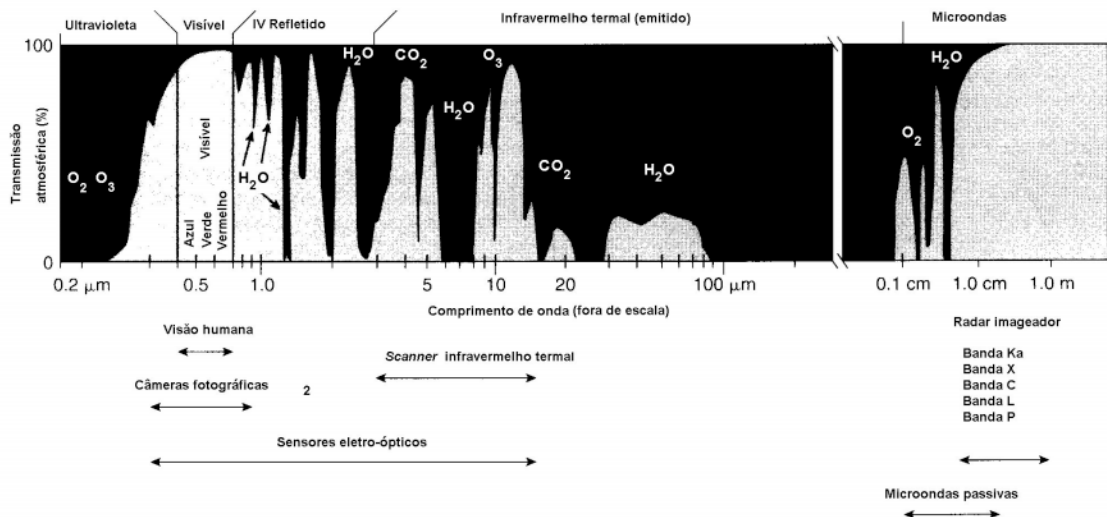


FIGURA 1 – PRINCIPAIS REGIÕES ESPECTRAIS, BANDAS DE ABSORÇÃO (EM PRETO) E JANELAS ATMOSFÉRICAS

FONTE: Adaptado de AVERY e BERLIN (1992)

CAMPBELL (1996) define três formas básicas de abordagem no sensoriamento remoto, dependendo dos comprimentos de onda detectados e do objetivo do estudo. A mais simples delas consiste em registrar a reflexão da radiação solar a partir da superfície terrestre. Nesse caso é utilizada, principalmente, a energia das porções do visível e infravermelho do espectro. A clareza da atmosfera, as propriedades espectrais dos objetos, ângulo e intensidade dos raios solares e a escolha

de filmes e filtros são algumas das variáveis fundamentais na aquisição dessas imagens.

Uma segunda estratégia para o sensoriamento remoto é o registro de radiações emitidas (ao invés de refletidas) da superfície da terra, que são, principalmente, derivadas da energia de ondas curtas do sol que foram absorvidas e, então, re-irradiadas em comprimentos de onda mais longos. A radiação emitida contém informações referentes às propriedades termais dos materiais, que podem ser interpretadas para descrever padrões de umidade, vegetação, materiais de superfície e edificações.

Uma terceira classe de instrumentos de sensoriamento remoto gera a sua própria energia e depois registra a reflexão dessa energia a partir da superfície terrestre. São os sensores denominados “ativos” por possuírem sua própria fonte de energia e serem independentes da radiação solar e terrestre. Exemplos de sensores ativos são os radares imageadores, que transmitem um sinal de microondas em direção à superfície terrestre a partir de uma aeronave ou satélite e, então, usam a energia refletida para formar uma imagem.

2.2 IMAGENS DIGITAIS

Sensores remotos, tais como câmaras fotográficas e *scanners* óptico-mecânicos, buscam detectar as diferenças em tonalidade ou cor entre os elementos da cena imageada ou entre um objeto e o ambiente. Quando os *photons* refletidos ou emitidos são representados em valores numéricos, tem-se uma imagem digital.

Uma imagem digital pode ser definida como uma matriz de quadrados ou retângulos denominados pixels. Cada pixel possui 3 coordenadas: valores de x e y que definem a posição do pixel na imagem e um valor de z (número inteiro) que representa o nível de cinza ou grau de brilho, ou seja, corresponde a uma unidade de informação em termos da quantidade de energia refletida e/ou emitida pelo objeto imageado, em diferentes comprimentos de onda no espectro eletromagnético (JAGELS e

TELEWSKI, 1989). Os níveis de cinza são também denominados DN_s, abreviatura do termo equivalente em inglês, *digital number*.

As imagens digitais da maioria dos sistemas de sensoriamento remoto são usualmente quantizadas em escalas de 6, 7, ou 8 bits para armazenagem em fita magnética ou disco (AVERY e BERLIN, 1992). A escala de 8 bits tornou-se padrão para os sensores eletro-ópticos e radares imageadores. Os níveis de quantização estão relacionados à amplitude de níveis de cinza disponíveis para a construção da imagem. Dessa forma, numa escala de 8 bits (2^8), a amplitude dos DN_s varia de 0 a 255, produzindo-se 256 diferentes níveis de cinza. Por convenção cenas de baixa radiância apresentam DN_s menores e mais próximos de zero, que equivale ao preto absoluto. Cenas de alta radiância apresentam DN_s maiores, aproximando-se de 255, que equivale ao branco absoluto.

2.3 SISTEMAS SENSORES

NOVO (1995) define sistemas sensores como quaisquer equipamentos capazes de transformar alguma forma de energia – eletromagnética, no caso do sensoriamento remoto – em um sinal passível de ser convertido em informação sobre o ambiente. Ao contrário das câmeras fotográficas, que registram a radiação refletida diretamente no filme, os sensores eletro-ópticos utilizam detectores que convertem a radiação emitida e/ou refletida no espectro óptico por uma cena no terreno em sinais proporcionais elétricos usados para construir imagens bi-dimensionais. Muitos dos sensores eletro-ópticos são sistemas digitais. Estas unidades usam um conversor analógico digital, que traduz os sinais eletrônicos dos detectores em números digitais (DN_s) discretos. Os principais tipos de sensores eletro-ópticos são a câmera de vídeo, a câmera vidicom e os *scanners* de varredura (AVERY e BERLIN, 1992).

Quanto ao tipo de transformação sofrida pela radiação detectada, pode-se classificar os sistemas sensores como não-imageadores ou imageadores. Dependendo do processo utilizado na formação da imagem, estes últimos se dividem em:

- a) sistemas de quadro: a imagem da cena é adquirida em sua totalidade num mesmo instante;
- b) sistemas de varredura (*scanning systems*): a imagem da cena é formada pela aquisição seqüencial de imagens elementares do terreno (pixels).

Os sistemas de varredura podem ser eletrônicos ou mecânicos. Os sensores TM a bordo dos satélites da série LANDSAT têm utilizado os sistemas de varredura mecânica.

Os sistemas sensores podem, ainda, ser classificados como passivos – que detectam a radiação solar emitida ou refletida – ou ativos, que produzem sua própria radiação. Entre estes últimos encontram-se os sensores de microondas ou radares.

2.3.1 Sensores Eletro-Ópticos de Varredura (*scanners*)

Os *scanners* eletro-ópticos possuem um espelho rotatório ou oscilante, que “varre” uma série contígua de estreitas faixas no terreno, perpendiculares à linha de vôo. O deslocamento da plataforma faz com que novas faixas sejam recobertas por sucessivas linhas de varredura. Assim é construído um registro bi-dimensional contendo a informação refletida e/ou emitida ao longo da linha de vôo

Os *scanners* multiespectrais são aqueles capazes de operar simultaneamente nas regiões do ultra-violeta, do visível e do infravermelho refletido e termal do espectro eletromagnético. Em se tratando de *scanners* montados em plataformas orbitais, durante cada varredura do espelho são recobertas múltiplas linhas de faixas no terreno (AVERY E BERLIN, 1992). Nos satélites para estudos ambientais, como, por exemplo, o LANDSAT 5, o *scanner* é formado pelo sensor Thematic Mapper e por 16 detectores, que são os equipamentos que efetivamente registram a energia eletromagnética para cada banda de comprimento de onda.

2.3.1.1 Sistema LANDSAT 5

O satélite LANDSAT 5 foi lançado em 1º de março de 1984, estando ativo, portanto, há cerca de 16 anos, apresentando, atualmente, indícios de degradação do sinal.

Para suprir essa deficiência já se encontra em operação, desde 1999, o satélite LANDSAT 7. No entanto, as imagens do sensor TM do LANDSAT 5 constituem um acervo considerável de dados históricos da superfície terrestre, sendo largamente empregadas em estudos geo-ambientais.

Operando a uma altitude de 705 km, num campo de visada de 14,9°, o sensor TM cobre uma superfície equivalente a 185 km X 185 km no terreno, coletando informações espectrais em 6 bandas no visível e no infravermelho refletido e em uma banda no infravermelho termal. Sua órbita é síncrona ao sol e sua periodicidade é de 16 dias.

As características das bandas espectrais do sensor TM do satélite LANDSAT 5 encontram-se relacionadas na Tabela 1.

O processamento das imagens LANDSAT 5 TM é efetuado em diversos níveis:

- a) nível 0 : sem correções geométricas;
- b) nível 4: correções geométricas ao longo da linha;
- c) nível 5: correções geométricas básicas, com reamostragem pelo método do “vizinho mais próximo”;
- d) nível 6: correções geométricas básicas, com reamostragem por “convolução cúbica”.

TABELA 1 – BANDAS ESPECTRAIS DO SENSOR THEMATIC MAPPER DO SATÉLITE LANDSAT 5

BANDA	INTERVALO ESPECTRAL (μm)	PRINCIPAIS APLICAÇÕES	CARACTERÍSTICAS	E
1	0,45 – 0,52 (azul)	Grande penetração em corpos d'água; absorção pela clorofila carotenóides; sensibilidade a plumas de fumaça; atenuação pela atmosfera.		
2	0,52 – 0,60 (verde)	Sensibilidade à presença de sedimentos em suspensão; boa penetração em corpos d'água.		
3	0,63 – 0,69 (vermelho)	Grande absorção pela vegetação densa, verde, uniforme (escura) → serve para diferenciar áreas com e sem vegetação; bom contraste entre diferentes tipos de cobertura vegetal (ex. campo, cerrado e floresta); banda mais utilizada para delimitação de mancha urbana; permite mapeamento da drenagem.		
4	0,76 – 0,90 (infra-vermelho próximo)	Grande absorção pelos corpos d'água (escuras), permitindo mapeamento da drenagem; sensibilidade à rugosidade do dossel florestal; mapeamento de feições geológicas e estruturais; diferenciação de coníferas e folhosas		
5	1,55 – 1,75 (infra-vermelho médio)	Sensibilidade ao teor de umidade das plantas → serve para detectar estresse fisiológico; sofre perturbações se ocorrer excesso de chuva antes da tomada da cena.		
6	10,4 – 12,5 (infra-vermelho termal)	Sensibilidade aos contrastes térmicos de rochas, solo, vegetação e água → útil para mapeamento termal		
7	2,08 – 2,35 (infra-vermelho distante)	Sensibilidade à morfologia do terreno; identificação de minerais com hidroxilas; discriminação de produtos de alteração hidrotermal.		

FONTE: INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (1996)

2.3.2 Comportamento Espectral de Alvos em Relação aos Sensores Ópticos

A utilização de dados de sensores remotos requer o conhecimento e a compreensão das características espectrais das várias feições terrestres e dos fatores que influenciam estas características (HOFFER, 1978). Esta compreensão da interação energia/matéria pode ser elementar para alguns materiais e inexistente para outros, lembrando que a caracterização espectral de um objeto não só depende da composição

do alvo como também das condições em que é efetuada (LILLESAND e KIEFER, 1994).

O conhecimento do comportamento espectral dos objetos da superfície terrestre e dos fatores que interferem neste comportamento é de fundamental importância no processo de extração de informações de dados de sensoriamento remoto. Este conhecimento é tão importante na extração de informações de imagens obtidas pelos sensores, como também na própria definição de novos sensores e na definição do tipo de processamento a que devem ser submetidos os dados brutos ou mesmo na forma de aquisição dos dados (NOVO, 1995).

Quando a energia eletromagnética incide em qualquer objeto da superfície terrestre, parte dessa energia é refletida, parte é absorvida e parte é transmitida, variando para diferentes feições, sendo dependente do tipo de material e condição do objeto. Quando são utilizados sensores ópticos, no espectro visível e no infravermelho próximo, mede-se a quantidade de energia que é refletida pelos objetos; já no infravermelho médio e termal, mede-se a emissão de energia pelos alvos da superfície terrestre (SMITH, 1983). Por outro lado, a discriminação de diferentes objetos em imagens de radar está diretamente relacionada com o retorno dos sinais de microondas para o sensor. Deste modo, na geração de uma imagem, esse retorno é caracterizado pela variação dos níveis de cinza para cada grupo de pixels, mostrando tonalidades diferentes para alvos distintos, o que influencia a possível interpretação de uma cena.

O conhecimento das propriedades de reflectância dos objetos terrestres é muito importante no estudo do comportamento espectral de cada alvo, auxiliando na identificação e separação de feições e na escolha adequada de bandas para cada estudo específico.

A energia radiante incidente na superfície terrestre interage com as feições terrestres e esta interação energia/matéria pode ser expressa pelas três propriedades radiométricas dos objetos: absorptância ou coeficiente de absorção (α), reflectância ou coeficiente de reflexão (ρ) e transmitância ou coeficiente de transmissão (τ). Estas propriedades são definidas como sendo as frações de energia incidente que são absorvidas, refletidas e transmitidas por um objeto, respectivamente. Pelo princípio da

conservação da energia, a interrelação entre energia incidente e suas frações pode se expressa pela equação:

$$1 = \alpha + \rho + \tau$$

As proporções dessas frações variam de uma feição para outra, dependendo do seu material, condições e comprimento de onda, permitindo a distinção de diferentes feições terrestres (LILLESAND e KIEFER, 1994). A propriedade mais importante em estudos de sensoriamento remoto, na área dos recursos naturais, é ainda a reflectância, devido aos sensores operarem em regiões de (0,4 a 3 μm) onde a energia refletida predomina (LILLESAND e KIEFER, 1994; PONZONI, 1993).

2.3.2.1 Água

Segundo HOFFER (1978); SALOMONSON et al. (1983) as respostas espectrais para a água variam com o comprimento de onda, de acordo com as interações entre a energia e a matéria. Corpos d'água absorvem quase toda energia incidente nos comprimentos de onda do infravermelho, havendo pouca energia para ser refletida. Esta característica permite identificar e delimitar mais facilmente os corpos d'água nas bandas do infravermelho. Além do infravermelho, alguns aspectos relacionados com as condições da água podem ser mais bem avaliados em comprimentos de onda do visível, onde as interações entre a energia e a matéria tornam-se muito complexas.

Os fatores que mais afetam a reflectância de um corpo d'água são determinados pelo meio-ambiente: profundidade da água, materiais em suspensão e rugosidade da lâmina d'água. Para águas rasas, a radiação refletida apresenta características do fundo e dos materiais em suspensão; para águas sem turbulência, a luz é refletida especularmente, tendo alta ou baixa reflectância, dependendo da localização do sensor; se a superfície d'água apresenta-se rugosa, aumenta-se o

espalhamento na superfície, e conseqüentemente, a reflectância (SALOMONSON et al., 1983).

Para KRITIKOS et al. (1974), a maior reflectância da água limpa se produz no intervalo espectral de 0,4 a 0,5 μm , reduzindo-se, aos poucos, até o infravermelho próximo, onde é praticamente nula; dados relacionados ao intervalo espectral de 0,6 a 0,7 μm sugerem a existência de 3 tipos distintos de água, havendo baixa, média e alta reflexibilidade. Águas límpidas têm baixa reflectância e águas com grande concentração de sedimentos têm alta reflectância.

2.3.2.2 Solo

As curvas de reflectância espectral dos solos são menos complexas que as da vegetação, em termos de aparência. As características mais marcantes são os valores crescentes de reflectância com o aumento do comprimento de onda. O solo é uma mistura complexa de materiais, com várias características físico-químicas, que afetam suas características espectrais. Diferentes tipos de solos possuem suas curvas típicas com formatos semelhantes, mas com diferenças na amplitude, devido a propriedades, tais como: conteúdo de água, quantidade de matéria orgânica e de óxido de ferro, granulometria e textura. Estes fatores são muito variáveis e estão bastante correlacionados, tornando sua interpretação complexa (HOFFER, 1978; LILLESAND e KIEFER, 1994).

A textura do solo e, conseqüentemente, a sua nomenclatura, são determinados pelas proporções de argila, silte e areia presentes nos mesmos (LILLESAND e KIEFER, 1994). Os solos argilosos são compostos de partículas muito pequenas, fato que os torna muito compactos, resultando em poucos espaços livres. Já nos solos arenosos, onde as partículas são maiores, ocorrem grandes espaços de ar entre as mesmas, permitindo um maior movimento de ar ou de água. A água presente no solo encontra-se localizada nestes espaços, entre as partículas, e também recobrimdo, com uma fina camada, cada uma delas. Nos solos argilosos, pelo fato de os espaços serem menores, a água não é drenada nem evaporada tão rapidamente quanto nos arenosos.

Esta relação entre conteúdo de água e tamanho das partículas tem influência na resposta espectral dos solos. Desta forma, quanto maior o conteúdo de água, menor a reflectância, principalmente nas bandas de absorção pela água. Em geral, segundo HOFFER (1978), uma das características dos solos secos é o aumento da sua reflectância com o aumento do comprimento de onda, particularmente em regiões do visível e infravermelho próximo.

As interações entre a energia e o solo não apresentam grande complexidade quando comparadas com a vegetação, pois a energia para o solo é absorvida ou refletida e, não necessariamente, transmitida para o material, como é o caso da vegetação. Devido ser o solo uma mistura complexa de materiais, o teor de umidade, a quantidade de matéria orgânica, a textura, a estrutura e o conteúdo de óxido de ferro influenciam significativamente sua reflectância espectral: o aumento da reflectância resulta do aumento de rugosidade, do baixo teor de umidade e de matéria orgânica (STONER e BAUMGARDNER, 1981). Deste modo, solos argilosos tendem a possuir um alto teor de umidade, forte estrutura e fina textura, causando uma baixa reflectância; ao contrário, solos arenosos tendem a apresentar uma estrutura fraca e um baixo conteúdo de umidade, tornando a reflexibilidade mais elevada; também, a presença de matéria orgânica no solo tende a escurecê-lo, reduzindo a sua reflectância. NOVO (1995), fazendo um comparativo com as rochas, menciona que estas apresentam um comportamento espectral semelhante ao dos solos, pois estes são produtos resultantes de alterações delas. Ressalta, ainda, que um dos elementos de maior diferenciação entre as curvas de rochas e solos é a presença de matéria orgânica nos solos.

COLEMAN e MONTGOMERY (1987), em estudos mais abrangentes das regiões do espectro, verificaram que a reflectância do solo aumenta continuamente da banda 1 (0,45 a 0,52 μm) para a banda 5 (1,55 a 1,75 μm), onde alcança a reflexão máxima, entrando em declínio na banda 7 (2,08 a 2,36 μm). Também verificou-se que a banda 7 é mais apropriada para estudos de teor de umidade, a banda 3 e a banda 5 mais apropriadas para avaliações de conteúdos de óxido de ferro e a banda 4 (0,76 a 0,94 μm) para estudos relacionados com a matéria orgânica do solo. Quanto à matéria

orgânica do solo, HOFFER (1978) salienta que é um fator influente na reflectância dos solos e seu nível indica a forma e a quantidade de nitrogênio existente, informação muito importante para o manejo adequado destes recursos. Os níveis de matéria orgânica podem variar de 0,5 a 5%, sendo que seu aumento proporciona uma coloração marron mais escura, resultando em uma redução nos valores de reflectância na região do visível. A presença de óxido de ferro geralmente está relacionada com a coloração vermelha de alguns solos e seu aumento causa uma diminuição na reflectância no visível. Muitos destes fatores descritos estão fortemente correlacionados, podendo de alguma forma dificultar a sua interpretação.

2.3.2.3 Vegetação

Em estudos de vegetação, um dos principais objetivos é o monitoramento das condições fisionômicas, fisiológicas e das mudanças ocorridas em áreas ocupadas por cobertura vegetal, as quais se expressam por alterações no processo energia/matéria (JACKSON e HUETE, 1991).

A reflectância da vegetação é influenciada por múltiplos fatores, como: geometria da folha, quantidade e arranjo das folhas, estrutura da planta (galhos e tronco), teor de umidade, condições climáticas e características do solo que isoladamente ou em conjunto provocam modificações no comportamento espectral (COLWELL, 1974).

Segundo HOFFER (1978), a reflectância da cobertura vegetal varia com o comprimento de onda (Figura 2). Na região do visível, a pigmentação das folhas é o fator dominante onde a maior parte da energia incidente é absorvida e o restante é refletido. No infravermelho próximo, os níveis de reflectância são controlados pela estrutura interna das folhas, onde aproximadamente metade da energia incidente é refletida, grande parte do restante é transmitida e pouca energia é absorvida pelas folhas. No infravermelho médio, o teor de umidade da vegetação controla a reflectância, onde grande parte da energia incidente é absorvida pela água presente nas

folhas. Nesta região do espectro, a reflectância aumenta com a redução do teor de umidade das folhas.

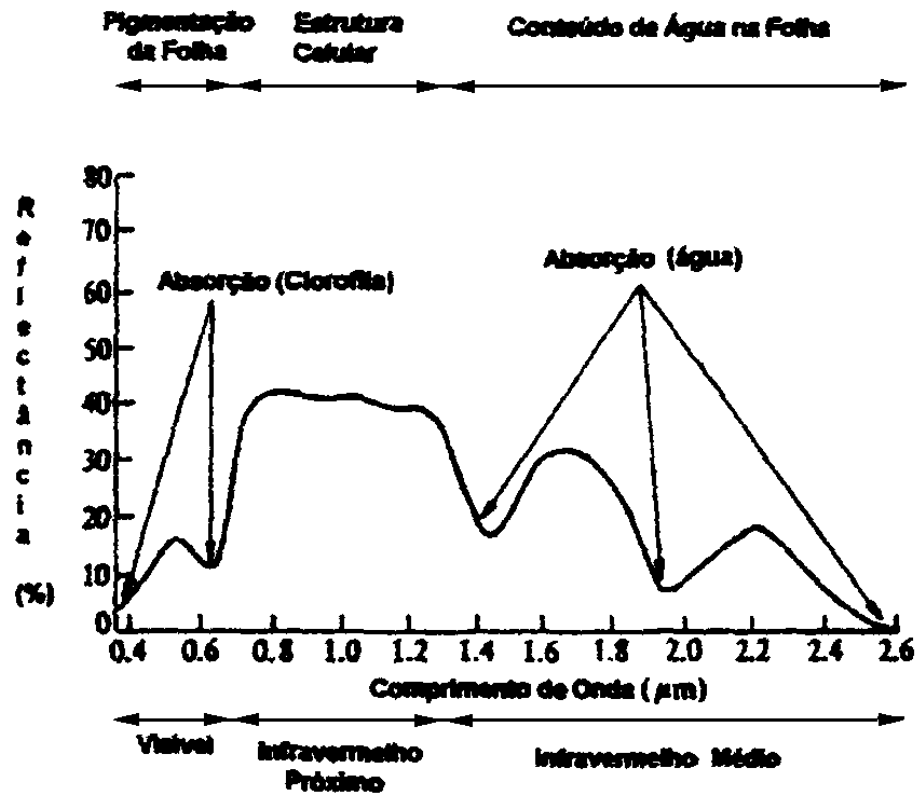


FIGURA 2 – COMPORTAMENTO ESPECTRAL TÍPICO DA VEGETAÇÃO SADIA
 FONTE: Modificado de HOFFER (1978)

Segundo CHUVIECO (1990), o contraste mais nítido na reflectância da vegetação sadia é produzido entre as bandas do visível, especialmente o azul e o infravermelho próximo. Quanto maior o contraste entre as bandas, maior será o vigor da vegetação e mais evidente a sua discriminação frente a outros tipos de cobertura. SZEKIELDA (1988) comenta que, apesar dos níveis de reflectância na região do infravermelho próximo serem altos para a vegetação em geral, mesmo assim ocorrem variações de espécie para espécie. Conforme se pode observar na Figura 3, nesta região espectral, as coníferas, em geral, apresentam valores inferiores aos das decíduas (LILLESAND e KIEFER, 1994).




FIGURA 3 – CURVAS DE REFLECTÂNCIA ESPECTRAL PARA DECÍDUAS (FOLHOSAS) E CONÍFERAS

FONTE: Adaptado de LILLESAND e KIEFER (1994)

Para HUNTER e BIRD (1970), a vegetação jovem possui três a quatro vezes maior reflectância que a vegetação senil, porém para espécies decíduas, folhas antigas refletem mais do que folhas novas. Também, para regiões muito secas, a maior reflexão da vegetação ocorre no espectro visível.

Para o estudo da vegetação, existem duas abordagens possíveis a partir de dados radiométricos: de folhas isoladas e de dosséis. SILVA e PONZONI (1995) apresentaram algumas considerações sobre a comparação entre a reflectância espectral de folhas isoladas e a reflectância espectral de dosséis. De um modo geral, a reflectância espectral de folhas isoladas é superior àquela apresentada pelos dosséis dos quais estas fazem parte. Os autores atribuíram este fato à presença de sombras no interior do dossel. Para SZEKIELDA (1988) a reflectância de um dossel é maior no

infravermelho próximo do que a reflectância de uma folha isolada, devido ao efeito aditivo da reflectância e transmitância entre as folhas. Estes resultados aparentemente controversos revelam a complexidade do processo de interação entre a Radiação Eletromagnética (REM) e a vegetação, no qual cada caso deve ser estudado isolada e cuidadosamente. Segundo KUMAR (1972), as variações na reflectância de um dossel dependerão da quantidade de folhas dentro do mesmo, de suas orientações espaciais e da própria arquitetura do dossel, das condições geométricas de iluminação e de visada e das características espectrais dos elementos que o compõe.

Na Figura 4 pode-se observar as curvas típicas de reflectância espectral para a vegetação em geral, solo e água, em relação à disposição das bandas do sensor TM no espectro refletido.

Em estudos de comportamento espectral de dosséis são exploradas, principalmente, as relações entre parâmetros biofísicos e a reflectância espectral. Dentre os parâmetros biofísicos mais explorados estão o Índice de Área Foliar (IAF) e a biomassa, expressa em peso seco de material vegetal ou por volume de material lenhoso.

KANEMASU (1974), em estudos realizados com sensores ópticos, em áreas de cultivo de trigo, sorgo e soja, verificou que a reflectância desses tipos de cobertura é menor quando as mesmas estão em fase de crescimento ou atrasadas no seu desenvolvimento, sendo a faixa do infravermelho próximo mais útil como índice para estudos de estágio de crescimento dessas culturas. Menciona também, que durante a estação de crescimento, a presença de solo exposto tem uma certa significância na reflectância da vegetação, sendo fortemente influenciada pelo teor de umidade da superfície. Posteriormente, RAO et al. (1979) trabalhando nesta mesma linha de pesquisa, verificaram que quando as culturas atingem a maturidade, a porção de solo exposto torna-se menor, ocorrendo predominância da reflectância da cobertura vegetal devido ao aumento da área foliar e da altura da planta.




FIGURA 4 – COMPORTAMENTO ESPECTRAL DA VEGETAÇÃO, SOLO E ÁGUA

FONTE: Adaptado de KAZMIERCZAK (1992)

2.3.3 Sensores de Microondas

Atualmente uma grande quantidade de informações sobre o ambiente e recursos naturais está sendo adquirida por sensores que operam na região de microondas do espectro eletromagnético. Entre estes inclui-se o radiômetro de microondas, que é um sensor passivo por apenas detectar o baixo nível de radiação de microondas natural que é emitido por todos os objetos da superfície terrestre (AVERY e BERLIN, 1992). O radar, por outro lado, é um sensor ativo que propaga radiação artificial de microondas em direção à superfície e detecta a componente refletida.

A palavra “radar” é um acrônimo da expressão *RA*dio *D*etection *A*nd *R*anging. O termo “radio” é usado porque os primeiros sistemas de radar empregavam ondas de radiação bastante longas (de 1 a 10 m), que se situam na bandas de rádio do espectro eletromagnético. Apesar de os sistemas radares atuais utilizarem energia de microondas, o acrônimo não foi alterado.

O processo de sensoriamento remoto por radar envolve a transmissão de pulsos curtos de energia de microondas na direção de interesse e o posterior registro da intensidade e origem dos “ecos” ou “reflexões” (retorno) recebidos dos objetos dentro do campo de visada do sistema (LILLESAND e KIEFER, 1994). Segundo AVERY e BERLIN (1992), **eco** é o registro tonal de uma imagem de radar e, portanto, é uma medida da intensidade do retorno de microondas.

A energia de microondas, sob o ponto de vista do sensoriamento remoto, é caracterizada pela capacidade de penetração na atmosfera sob quaisquer condições climáticas, pois os comprimentos de onda nessa faixa do espectro são longos o suficiente para evitar a interferência de nuvens e chuva leve (CAMPBELL, 1996).

Sendo um sensor ativo, o radar emite sua própria radiação, operando independentemente da luz do sol, o que lhe permite adquirir imagens da superfície terrestre durante o dia ou a noite. Além disso, o ângulo e a direção de iluminação por microondas podem ser controlados para realçar as feições de interesse (AVERY e BERLIN, 1992).

A natureza dos fenômenos de superfície envolvidos no imageamento por radar é inerentemente diversa daquelas de imagens no visível/infravermelho. Quando a radiação visível/infravermelha atinge uma superfície, ela é absorvida ou refletida ou transmitida. A absorção é baseada nas ligações moleculares do material. Assim, esta imagem fornece informações sobre a composição química dos alvos. No caso do radar, quando as microondas atingem uma superfície, elas são refletidas mais de acordo com as propriedades físicas e elétricas do alvo do que pela composição química. A interação das ondas de radar com a superfície de interesse é dominada pela reflexão envolvendo a rugosidade de superfície na escala do comprimento de onda (ERDAS, 1997).

Analogamente aos *lasers*, os radares são monocromáticos pelo fato de usarem radiação de comprimentos de onda únicos. Na Tabela 2 encontram-se relacionadas as subdivisões ou bandas do espectro de microondas, bem como seus respectivos comprimentos de onda e aquelas mais comumente usadas nos radares imageadores.

TABELA 2 – DESIGNAÇÃO DE BANDAS, COMPRIMENTOS DE ONDA E FREQUÊNCIAS DE RADAR

Banda	Amplitude de comprimentos de onda (cm)	Frequência (GHz)
K _a	0,8 – 1,1	40,0 – 26,5
K	1,1 – 1,7	26,5 – 18,0
K _u	1,7 – 2,4	18,0 – 12,5
X	2,4 – 3,8	12,5 – 8,0
C	3,8 – 7,5	8,0 – 4,0
S	7,5 – 15,0	4,0 – 2,0
L	15,0 – 30,0	2,0 – 1,0
P	30,0 – 100,0	1,0 – 0,3

FONTE: Compilado de AVERY e BERLIN (1992) e SABINS (1997)

Os componentes básicos de um sistema de radar imageador incluem um transmissor, um receptor, um corpo de antena e um gravador (CAMPBELL, 1996). O transmissor é projetado para transmitir pulsos repetitivos de energia de microondas numa dada frequência. O receptor aceita o sinal refletido recebido pela antena, filtrando-o e amplificando-o quando necessário. A antena é projetada para transmitir um estreito feixe de energia de microondas e é formada por guias de onda, que são dispositivos que controlam a propagação de uma onda eletromagnética, de tal forma que as ondas seguem uma trajetória definida pela estrutura física da guia. Geralmente a mesma antena é usada tanto para transmitir o sinal de radar, como para receber o seu “eco” do terreno. Finalmente um gravador registra e/ou mostra o sinal como uma imagem.

2.3.3.1 Radar de visada lateral (SLAR)

Os radares aerotransportados de visada lateral (SLAR) são sensores ativos cuja capacidade de detecção de distâncias se baseia na medição do intervalo de tempo ocorrido entre a transmissão do sinal da antena para o terreno e a recepção do seu eco

(CAMPBELL, 1996). Além disso, o SLAR é capaz de detectar alterações de frequência e de polarização.

As imagens SLAR são adquiridas por uma antena apontada para a lateral da aeronave que, através da transmissão e recepção de um sinal de microondas imageia uma faixa do solo paralela a rota de vôo da aeronave. A reflexão do sinal de microondas do solo para a antena forma a base para a imagem.

Por produzir imagens com radiação incidindo obliquamente no terreno e por usar uma parte distinta (região de microondas) do espectro eletromagnético, o SLAR pode fornecer informações da topografia e bacias de drenagem das áreas visadas com muita nitidez, apresentando informações adicionais e diferentes daquelas obtidas através de fotografias aéreas e sensores que operam no espectro visível e infravermelho.

2.3.3.1.1 Sistema radar de abertura real (RAR)

Os radares de abertura real são os mais antigos, simples e baratos sistemas de imageamento por microondas e possuem a estrutura básica do SLAR (CAMPBELL, 1996). O transmissor gera um sinal de duração e comprimentos de onda específicos que, por sua vez, são direcionados para o terreno através da antena. O sinal refletido é captado pela antena, filtrado, amplificado e apresentado num monitor, onde um filme registra a imagem, linha por linha, acompanhando o movimento da aeronave.

A resolução das imagens adquiridas por esse sistema depende do tamanho da área iluminada. A iluminação de áreas menores permite que seja mantida a identidade de feições individuais, enquanto que áreas grandes proporcionam o efeito indesejável da formação de ecos médios de muitos objetos. O tamanho da área iluminada é controlado pelo comprimento da antena em relação ao comprimento de onda. Antenas longas permitem que a energia seja focada em uma pequena área do terreno, gerando imagens com detalhes espaciais finos.

Outro meio de se definir a resolução nos sistemas radares é o comprimento do pulso de radar, que determina a habilidade do sistema em distinguir dois objetos

próximos na direção perpendicular à rota da aeronave (CAMPBELL, 1996). Entende-se por pulso o tempo decorrido desde a emissão do sinal até a sua recepção. Pulsos mais curtos produzem ecos distintos, enquanto que pulsos mais longos atingem ambos os objetos ao mesmo tempo, registrando-os como uma feição única na imagem.

2.3.3.1.2 Sistema radar de abertura sintética (SAR)

A principal desvantagem do radar de abertura real é que a sua resolução azimutal é limitada pelo comprimento da antena. Procurando superar essas dificuldades, foi desenvolvido o radar de abertura sintética (SAR), que produz, artificialmente, uma antena longa, virtual, denominada “antena de abertura sintética” (Figura 5), que forma a base do sistema SAR (LYBANON, 1973). O deslocamento da plataforma é utilizado para transportar uma antena real relativamente curta ao longo de posições sucessivas na linha de vôo. Assim, essas porções sucessivas são tratadas eletronicamente, como se cada uma fosse um elemento individual da mesma antena (AVERY e BERLIN, 1992). O comprimento da antena sintética é diretamente proporcional ao alcance do feixe radar na direção perpendicular à trajetória. Conseqüentemente o feixe sintético produzido possui largura e resolução azimutal constantes, independentemente do alcance do sistema radar.

Segundo CRACKNELL e HAYES (1993), o SAR é um sofisticado sistema de radar com técnicas modernas de processamento de sinais. Basicamente, possui um transmissor convencional de microondas, uma antena e um receptor, que, acoplados a um processador de sinais, permitem a obtenção de imagens da superfície terrestre.

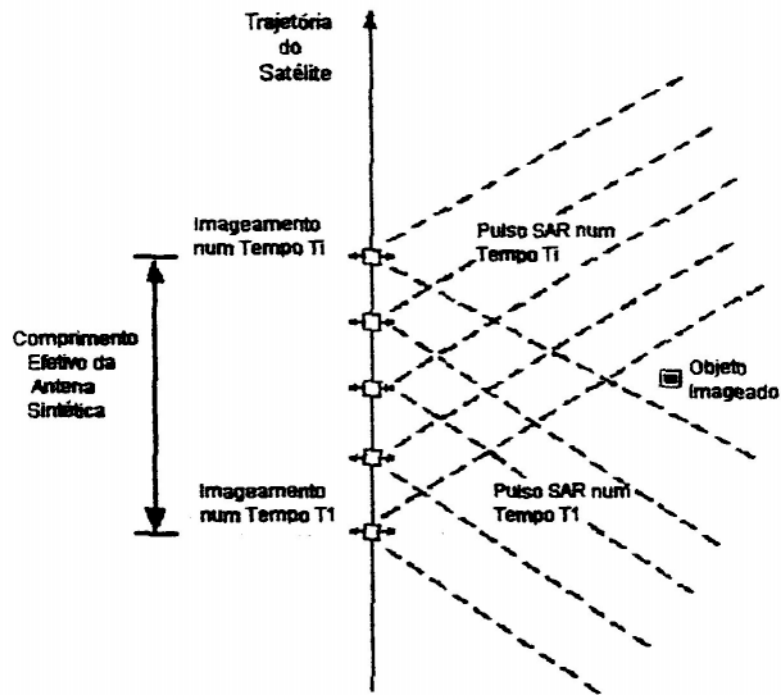


FIGURA 5 – DIAGRAMA DE OPERAÇÃO DE UMA ANTENA SINTÉTICA

FONTE: SILVA JR. (1999)

No sistema SAR, um feixe de microondas permanece por um determinado tempo sobre cada alvo, registrando várias medidas sobre o mesmo ponto, enquanto ocorre o deslocamento do sistema (FITCH, 1988). Isso o diferencia do radar de abertura real (RAR), que registra apenas um pulso para cada alvo na formação das células de resolução. O radar de abertura sintética usa o efeito *Doppler* para estabelecer as alterações de frequência nos ecos, causadas pelo deslocamento relativo entre os objetos no terreno e a plataforma, o que, por sua vez, determina a resolução azimutal (AVERY e BERLIN, 1992; CAMPBELL, 1996). Se a feição é imageada pelo feixe radar à frente da plataforma, os seus ecos produzem uma alteração para frequências mais altas (*Doppler* positivo); quando a plataforma está perpendicular à posição do alvo, não há alterações na frequência (*Doppler* zero); à medida que a plataforma se move para além do objeto considerado, os ecos possuem frequências mais baixas (*Doppler* negativo) do que o sinal transmitido (Figura 6). A informação

sobre as modulações de frequência é obtida eletronicamente, comparando os sinais refletidos por uma dada feição com um sinal de referência que incorpora a mesma frequência do pulso transmitido (AVERY e BERLIN, 1992). Como resultado obtém-se um histórico das fases, contendo o registro das alterações de frequência *Doppler* e a amplitude dos sinais de retorno de cada feição no terreno, à medida que esta passou através do feixe da antena. Esse histórico é gravado em filme ou em fitas digitais de alta densidade, sendo, depois, reconstruído através de complexos algoritmos (técnicas ópticas e digitais, respectivamente). Segundo CRACKNELL e HAYES (1993) as técnicas ópticas têm a vantagem de produção de imagens em pequeno espaço de tempo, porém possuem a desvantagem de menor qualidade da imagem final quando comparadas com técnicas digitais.




FIGURA 6 – FATORES DETERMINANTES DA RESOLUÇÃO NO RADAR DE ABERTURA SINTÉTICA

FONTE: Adaptado de LILLESAND e KIEFER (1994)

Devido ao ruído típico das imagens de radar (*speckle*), que provoca uma degradação nas imagens SAR, utiliza-se uma técnica de processamento que faz aumentar a relação sinal-ruído nessas imagens. Essa técnica é conhecida como “processamento *multi-look*” e consiste em dividir a antena de abertura sintética em várias visadas (*looks*), como pode ser observado na Figura 7.

A imagem final é representada pela média das imagens de cada *look*, que são obtidas separadamente e consideradas estatisticamente independentes entre si; em geral, três ou quatro *looks* são usados na produção de uma imagem “*multi-look*” (FITCH, 1988). Esse processamento provoca uma certa perda de resolução azimutal, compensada por uma melhor qualidade visual da imagem.

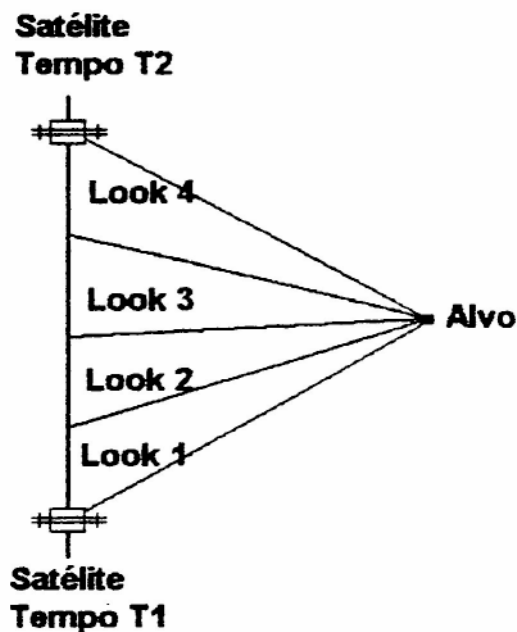


FIGURA 7 – ESQUEMA DE FUNCIONAMENTO DE ANTENA SINTÉTICA COM 4 LOOKS

FONTE: SILVA JR. (1999)

2.3.3.2 Geometria de um radar imageador

Uma das características mais aparentes da imagem de radar é o seu caráter de iluminação lateral, que se origina de variações na geometria relativa sensor/terreno, para diferentes orientações do terreno (LILLESAND e KIEFER, 1994). Na Figura 8 são apresentadas as características geométricas dos radares aerotransportados de visada lateral (SLAR). A direção na qual a aeronave se movimenta, voando a uma determinada altitude, é denominada **direção de azimute**. Os **pulsos** da radiação de microondas são propagados à velocidade da luz na direção perpendicular à trajetória. **Projeção oblíqua** (*Slant range*) é a distância da antena ao alvo no terreno medida sobre o plano inclinado formado pelo feixe radar. A **projeção no terreno** (*ground range*) é a distância horizontal medida ao longo da superfície a partir da **linha do nadir** ou **trajetória no terreno** até o alvo. A área mais próxima à trajetória no terreno, na qual o pulso radar intercepta a superfície, é denominada **projeção próxima** (*near range*), enquanto que a área onde o pulso de radar termina e que fica mais distante da trajetória no terreno é a **projeção distante** (*far range*).

O ângulo medido entre um plano horizontal em direção descendente até uma parte específica do feixe radar define o **ângulo de depressão**. Ele varia através da **faixa imageada**, assumindo valores relativamente grandes na região da **projeção próxima** e valores pequenos na **projeção distante**. O ângulo medido a partir de um plano vertical, para cima, até uma parte específica do feixe radar define o **ângulo de visada**, que varia através da faixa imageada, assumindo valores relativamente pequenos na **projeção próxima** até relativamente grandes na **projeção distante**. Quando medidos na mesma parte do feixe, os **ângulos de depressão** e de **visada** são complementares, ou seja, a sua soma é igual a 90° .

O **ângulo de incidência** é o ângulo medido entre o eixo do feixe radar e uma linha perpendicular à superfície local do terreno que o feixe atinge; o complemento do ângulo de incidência é denominado **grazing angle**. Conseqüentemente, ambos são função do ângulo de iluminação (de depressão ou de visada) e da inclinação do terreno

(AVERY e BERLIN, 1992). Quando o terreno é horizontal o ângulo de depressão e o *grazing angle* são iguais e os ângulos de visada e de incidência são iguais.

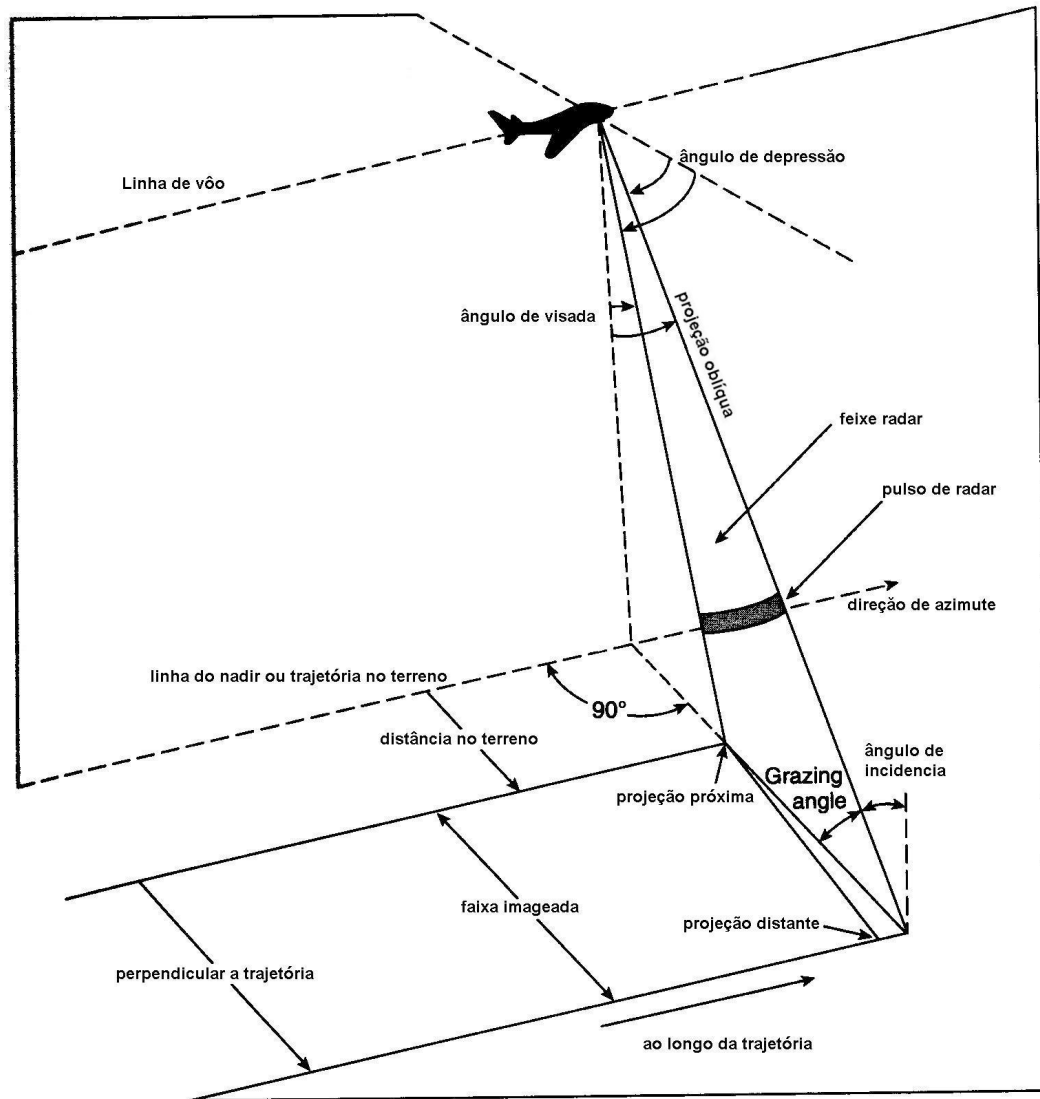


FIGURA 8 – CARACTERÍSTICAS GEOMÉTRICAS DO SLAR
 FONTE: Modificado de AVERY e BERLIN (1992)

A geometria das imagens SLAR é fundamentalmente diferente daquelas que se originam de sensores no espectro óptico. Isso ocorre pelo fato de o SLAR ser um sistema de medição por distância e não, por ângulo (LILLESAND e KIEFER, 1994). O sistema de radar mede a distância ao alvo medindo o tempo que um sinal transmitido demora em retornar à antena. Considerando-se a velocidade da energia

eletromagnética constante, a medida do tempo é convertida diretamente para a medida da distância da antena.

Como os radares coletam toda a informação no domínio da **projeção oblíqua** (*slant range*), imagens de radar inerentemente contêm distorções geométricas (CAMPBELL, 1996). Duas dessas distorções são o **encurtamento de rampa** (*foreshortening*) e a **inversão de relevo** ou **inversão topográfica** (*layover*), que ocorrem principalmente na presença de relevo ondulado a fortemente ondulado. A extensão de tempo que o feixe radar leva para iluminar um aclave da sua base até o seu topo, determina a sua extensão em uma imagem de radar. Uma vez que demora menos tempo para iluminar o aclave do que o declive de um morro, por exemplo, o eco correspondente ao aclave será relativamente mais curto do que aquele do declive. Assim, a parte do aclave aparecerá encurtada ou comprimida em relação à sua extensão real. O grau de **encurtamento** é função da geometria de iluminação e do ângulo do aclave, sendo que as compressões mais severas ocorrem na **projeção próxima** (AVERY e BERLIN, 1992).

A curvatura de um pulso de radar transmitido faz com que o topo de uma feição vertical alta reflita energia antes que sua base, o que resulta no deslocamento do topo em relação à porção da **projeção próxima** da imagem (SABINS, 1997). Tal efeito é denominado **inversão de relevo** (*layover*) e pode ser considerado como um caso extremo do **encurtamento de rampa** (*foreshortening*) (AVERY e BERLIN, 1992). A **inversão de relevo** tende a ocorrer principalmente quando aclives muito íngremes são encontrados na porção da **projeção próxima**. O efeito pode ser minimizado adquirindo-se imagens com ângulos de depressão pequenos, mas as **sombras de radar** (*shadows*) resultantes podem ser excessivas para terrenos com relevo acidentado (SABINS, 1997).

Pelo fato de o radar iluminar o terreno ao longo da linha de visão, ou seja, com iluminação unilateral, as feições topográficas mais proeminentes podem impedir que o feixe de radar atinja a sua parte posterior ou declive. Não sendo iluminadas, essas regiões não produzirão sinais de retorno; como aparecem em tons pretos na imagem são denominadas **sombras de radar**. Muitas vezes estendem-se além da base de um

declive, mascarando todas as feições que aí se encontram. A criação de uma sombra de radar é determinada pelo ângulo do declive e pelo ângulo de depressão da antena. Geralmente o sombreamento ocorre com maior frequência em ângulos de depressão pequenos, porque a iluminação do radar torna-se mais oblíqua na **projeção distante** (*far range*). Os termos “*near range*” e “*far range*” podem ser também denominados de **canal próximo** e **canal remoto** ou **distante** respectivamente (LIMA, 1995).

AVERY e BERLIN (1992) citam quatro características importantes referentes às sombras de radar:

- a) uma sombra de radar somente pode ocorrer na direção perpendicular à trajetória, para longe da antena. Quando as sombras estão presentes, o fenômeno permite identificar as porções da projeção próxima e projeção distante da imagem de radar;
- b) mantendo-se constante a distância, uma feição mais alta produzirá sombra maior;
- c) uma feição que projeta uma sombra extensa na projeção distante pode ter seu declive completamente iluminado na projeção próxima;
- d) a forma das sombras de radar imita perfis topográficos, constituindo uma ferramenta útil na interpretação de imagens.

2.3.3.3 Resolução

Uma imagem obtida a partir de um sistema de microondas apresenta dois tipos de resolução: resolução azimutal (R_a) e resolução transversal ou resolução no solo (R_t), representadas na Figura 6.

As resoluções estão vinculadas a parâmetros do imageamento, tais como: duração do pulso, ângulo de incidência, largura do feixe de microondas, comprimento da antena, etc. Definem, para cada posição na imagem, o pixel, elemento de resolução espacial.

2.3.3.3.1 Resolução azimutal

A resolução azimutal ou ao longo da trajetória é determinada pela largura da faixa do terreno sendo iluminada pelo pulso radar, que, por sua vez, é função da largura do feixe de um radar de abertura real (AVERY e BERLIN, 1992).

Segundo ELACHI (1987), quando o sistema de imageamento é efetuado com um radar de abertura real, a resolução em azimute é dada pela equação:

$$R_a = \frac{h \cdot \lambda}{d \cdot \cos \theta}$$

Onde:

R_a = resolução azimutal

h = altitude de vôo;

λ = comprimento de onda;

d = comprimento real da antena;

θ = ângulo de incidência.

Este sistema utiliza as dimensões reais da antena para o imageamento lateral da superfície terrestre, portanto, quanto menor for o comprimento da antena, pior será a resolução azimutal.

Para o sistema Radar de Abertura Sintética (SAR), a resolução em azimute é modificada devido à “antena sintética” (ELACHI, 1987), conforme detalhado no item 2.3.3.1.2. A resolução azimutal é calculada pela seguinte fórmula:

$$R_a = \frac{d}{2}$$

em que:

R_a = resolução azimutal

d = comprimento real da antena

Para o sistema SAR, a resolução azimutal é independente da distância entre a antena e o alvo, altura de vôo, ângulo de incidência e comprimento de onda utilizados no imageamento.

2.3.3.3.2 Resolução transversal ou resolução espacial

Segundo NOVO (1995), a resolução espacial resulta da divisão da cena imageada em um grande número de elementos discretos de informação. Conforme LILLESAND e KIEFER (1994), a resolução transversal, R_t é dada por:

$$R_t = \frac{c \cdot \tau}{2 \cos \theta_d}$$

Onde:

τ = duração de um pulso (diferença de tempo entre a emissão e a recepção)

c = velocidade da luz

θ_d = ângulo de depressão

A resolução transversal é a projeção no solo da resolução na linha de visada ou resolução espacial em distância. Esta resolução é melhorada com o aumento da distância entre o sensor e o alvo.

2.3.3.4 Fatores que afetam os sinais de retorno do radar

A discriminação de diferentes objetos em imagens de radar está diretamente relacionada com o retorno dos sinais das microondas para o sensor. Cada imagem de radar é composta de muitos elementos de variado brilho. Essas variações correspondem, pelo menos em parte, às alterações de lugar para lugar dentro da paisagem. O conhecimento dessa correspondência constitui a base para inferências sobre as propriedades da paisagem. No entanto, a maior dificuldade para uma interpretação rigorosa de uma imagem de radar reside no fato de que os sinais que

retornam do terreno possuem grande amplitude de variação, gerando desde baixos níveis de brilho (imagens escuras) até altos níveis (imagens claras).

O registro tonal de uma imagem de radar é, portanto, uma medida da intensidade do retorno (eco) de microondas e resulta de uma série de propriedades da superfície e do sistema radar (AVERY e BERLIN, 1992). Objetos que são bons refletores aparecem em tons claros nas imagens de radar; os maus refletores aparecem em tons escuros. Aqueles cujo sinal de retorno não é mensurável aparecem em preto. Objetos que são refletores moderados são representados em tons médios. Para muitos alvos da superfície terrestre as assinaturas tonais das imagens de radar apresentam-se de forma reversa àquelas observadas em fotografias que representam as porções visível e infravermelho do espectro. Na Tabela 3 encontram-se sumarizadas algumas das classes de feições mais comuns e suas respectivas intensidades de eco e tonalidades apresentadas nas imagens de radar.

Segundo AVERY e BERLIN (1992), a intensidade do retorno dos sinais de radar depende dos parâmetros do sensor radar (comprimento de onda, ângulo e direção de visada, ângulo de depressão e polarização) e dos parâmetros inerentes ao alvo (orientação das feições, relevo, permitividade e rugosidade).

2.3.3.4.1 Relevo e ângulo de depressão

Os terrenos cujos aclives estão voltados para a origem do sinal de radar (antena) produzem retorno intenso, sendo que a maior quantidade de reflexão ocorre quando o aclive é perpendicular ao feixe radar (AVERY e BERLIN, 1992). Essa condição, conhecida como incidência normal, significa que as trajetórias de incidência e reflexão são as mesmas e se verifica sempre que a soma do ângulo de depressão e do ângulo de aclive é igual a 90° . A incidência normal pode mascarar todas as informações relativas ao micro-relevo do aclive produzindo uma área excessivamente brilhante na imagem.

TABELA 3 – CLASSES DE FEIÇÕES E AMPLITUDES TONAIIS REPRESENTATIVAS EM IMAGENS SLAR

FEIÇÕES	CARACTERÍSTICAS DE REFLEXÃO	AMPLITUDE TONAL
<i>Topográficas</i>		
Terreno plano	Reflexão especular se liso; retorno fraco ou ausente	Tons escuros a pretos
Aclive	Retorno relativamente forte; máximo retorno quando há incidência normal	Tons médios a claros
Declive	Retorno relativamente fraco; sem retorno quando a encosta não é iluminada (sombra de radar)	Tons médios a escuros; pretos
<i>Geológicas</i>		
Superfícies lisas	Reflexão especular quando o terreno é relativamente plano; retorno fraco ou ausente	Tons escuros a pretos
Superfícies rugosas	Reflexão difusa; retorno moderado a forte	Tons médios a claros
Superfícies lisas e rugosas	Reflexão influenciada pela inclinação topográfica	Tons mais claros produzidos pelo efeito dos aclives
	Reflexão influenciada pelo conteúdo de umidade (influência da constante dielétrica da água, quando a água não produz uma superfície lisa)	Tons mais claros produzidos com o aumento do conteúdo de umidade
“Refletores de canto” naturais	Máximo retorno com ângulo de orientação apropriado	Tons bem claros
<i>Hidrologia e gelo</i>		
Superfícies de água e gelo lisas	Reflexão especular; retorno fraco ou ausente	Tons escuros a pretos
Superfícies de água e gelo rugosas	Reflexão difusa; retornos moderados a fortes	Tons médios a claros
<i>Vegetação</i>		
Floresta densa	Reflexão difusa; retornos moderados a fortes; intensidade do retorno depende de variáveis tais como densidade, espécie (coníferas vs. folhosas), ausência ou presença de água)	Tons médios a claros
Campo	Reflexão especular e difusa; retornos moderados a fortes; intensidade do retorno depende de variáveis tais como microrrelevo, presença ou ausência de água, comprimento de onda	Tons médios a escuros
Agricultura	Retorno variável de forte a fraco; intensidade do retorno depende de variáveis tais como densidade, microrrelevo, presença ou ausência de água, comprimento de onda	Tons mais claros produzidos com o aumento do conteúdo de umidade
<i>Alvos culturais</i>		
Ruas, auto-estradas	Reflexão especular; retorno fraco ou ausente	Tons escuros a pretos
Estradas de ferro, navios, pontes, linhas de transmissão e outros objetos de metal	Máximo retorno com ângulo de orientação apropriado	Tons bem claros
Refletores de canto produzidos por paredes verticais interseccionando planos horizontais no terreno	Máximo retorno com ângulo de orientação apropriado	Tons bem claros

FONTE: Adaptada de AVERY e BERLIN (1992)

De maneira análoga, os declives do terreno produzem tons escuros, ou seja, possuem baixo retorno quando iluminados pelo radar. Os sinais de retorno serão mais fortes quando o ângulo do declive for menor que o ângulo de depressão. As diferenças

de retorno entre aclives e declives enfatiza a topografia na interpretação de imagens de radar. Com relação a este aspecto, LOCH (1982) concluiu que a imagem de radar é mais eficiente do que a imagem LANDSAT para avaliar o traçado da rede de drenagem.

2.3.3.4.2 Rugosidade

A influência da rugosidade da superfície causa mudanças no retorno das microondas ao sistema radar, sendo um fator dominante na tonalidade da imagem. A rugosidade é medida em centímetros e é determinada pelas características texturais, que são comparáveis, em tamanho, ao comprimento de onda do radar (SABINS, 1997).

Segundo SIMONETT e DAVIS (1983), quanto maior a rugosidade de uma superfície mais difusa será a radiação espalhada (reflexão difusa), aumentando o espalhamento dos sinais. Para superfícies lisas (Figura 9b), pouca radiação retorna para a antena (reflexão especular), diminuindo o espalhamento dos sinais.




FIGURA 9 – REFLEXÃO DOS SINAIS DE RADAR PARA VÁRIAS SUPERFÍCIES

FONTE: Adaptado de LILLESAND e KIEFER (1994)

As tonalidades escuras nas imagens de radar são associadas a corpos d'água, refletindo especularmente toda a energia. Uma superfície com rugosidade intermediária reflete, especularmente, parte da energia, ocorrendo dispersão da outra parte (apresenta tonalidades de brilho intermediário). Uma superfície muito rugosa (Figura 9a), dispersa toda a energia incidente e, conseqüentemente, produz imagens mais brilhantes (ULABY et al.,1982).

Pequenos objetos podem parecer extremamente brilhantes em imagens de radar; isto é devido, principalmente, à configuração geométrica do objeto. Quando duas ou três superfícies se interceptam formando ângulos retos ou quando estão voltados para o sensor radar, forma-se um **refletor de canto** (*corner reflector*) (Figura 9c), fazendo com que o sinal de retorno seja forte (FUNG e ULABY, 1983).

A configuração geométrica mais favorável para esta situação encontra-se nas estruturas construídas: reflexões de um lado de um edifício combinados com reflexões do terreno, reflexões de navios, pontes, etc. Em alguns casos, reflectores de canto tornam-se úteis na localização de alvos que podem ser utilizados como pontos de apoio para o referenciamento da imagem em um sistema de projeção (GUPTA, 1991; CANADA, 1995).

2.3.3.4.3 Permittividade

Permittividade é parâmetro descritor das características elétricas dos materiais presentes em uma cena imageada por microondas. É definida como uma variável complexa e está associada à constante dielétrica dos materiais e à quantidade de energia que pode ser perdida na forma de calor ou energia química (ELACHI, 1987). Esse parâmetro é indicador da refletividade e condutividade de vários materiais (LILLESAND e KIEFER, 1994). Desse modo, quando microondas detectam a presença de água, grande parte da energia espalha-se na superfície devido à constante dielétrica da água, em torno de 80 (imagem clara). Por outro lado quando há presença de superfícies secas, a penetração das microondas é maior, pois o valor da constante dielétrica diminui sensivelmente, situando-se entre 3 e 8 (imagem escura). Assim,

segundo ULABY et al. (1974), quanto menor o conteúdo de água em uma superfície, maior será a penetração dos sinais de radar nessa superfície. Os dosséis das plantas, com suas variadas e complexas constantes dielétricas e seu micro-relevo, freqüentemente dominam a textura dos tons de imagens SLAR (LILLESAND e KIEFER, 1994).

2.3.3.4.4 Polarização

Polarização é o fenômeno que descreve a orientação do plano do vetor *campo magnético* de uma onda, observado na direção de propagação. Em geral, os sistemas imageadores de radar emitem e recebem ondas linearmente polarizadas, ou seja, produzem ondas eletromagnéticas com um campo elétrico em um plano fixo na direção de propagação.

Os radares são projetados de forma a transmitir e receber ondas em polarização horizontal (H) e/ou vertical (V). Assim, a notação HH indica um radar que emite onda na polarização horizontal, recebendo a onda de retorno na mesma polarização de origem e VV representa polarizações verticais em emissão e retorno, sendo denominadas polarizações paralelas. Existem também as polarizações denominadas polarizações cruzadas do tipo HV e VH, onde a onda transmitida pelo radar é captada em uma polarização diferente da onda emitida.

Em geral os ecos de radar a partir da superfície são fortes na polarização paralela (HH ou VV) e mais fracos na polarização cruzada (HV ou VH) (AVERY e BERLIN, 1992).

A polarização, segundo FUNG e ULABY (1983), é um fator importante no que se refere ao retorno dos sinais, podendo contribuir para a discriminação de diferentes objetos na superfície terrestre. Deste modo, para determinadas culturas a diferenciação pode ser facilitada a partir do uso de polarizações cruzadas assim como o uso de polarizações paralelas permite maior profundidade de penetração em áreas florestais com solos secos. Devido à complexa maneira de interação dos sinais de radar com as feições e, também, pela sua dependência do relevo, rugosidade, cobertura

vegetal e conteúdo de umidade do solo e da vegetação, nem sempre é possível prever se imagens HH ou HV apresentarão um maior conteúdo de informação para uma determinada aplicação (LILLESAND e KIEFER, 1994).

Em sistemas radares de polarização paralela, os retornos mais intensos ocorrem quando os difusores de superfície estão orientados na mesma direção da polarização do raio incidente (AVERY e BERLIN, 1992). Por exemplo, a polarização VV é mais sensível a caules de plantas e troncos de árvores devido à sua orientação vertical.

2.3.3.4.5 Direção de visada da antena e orientação das feições

Independentemente do comprimento de onda, há uma significativa relação entre a direção de visada do radar, a assinatura da imagem e a orientação das feições lineares no terreno (SABINS, 1997). Tal relação desempenha um papel importante na determinação da intensidade do eco e, por conseguinte, na detectabilidade das feições na imagem (AVERY e BERLIN, 1992). As feições orientadas paralelamente à direção de visada ficam suprimidas e difíceis de se reconhecer (SABINS, 1997). O máximo sinal de retorno ocorre quando a iluminação do radar forma um ângulo reto com a orientação da feição de interesse. Imagens de direções de múltiplos *looks* (Figura 7) podem aumentar consideravelmente o conteúdo dos dados (AVERY e BERLIN, 1992). GELNETT (1978) afirma que são necessários quatro *looks* ortogonais para se obter a máxima quantidade de dados disponíveis a partir de uma imagem de radar:

Quatro <i>looks</i> ortogonais	= 100% do conteúdo dos dados
Dois <i>looks</i> opostos	= 90% do conteúdo dos dados
Dois <i>looks</i> ortogonais	= 80% do conteúdo dos dados
Um <i>look</i>	= 70% do conteúdo dos dados

Em áreas urbanas a orientação de ruas e edifícios em relação à direção de visada também influencia as assinaturas (SABINS, 1997). Feições lineares de metal,

tais como cercas e trilhos possuem assinaturas brilhantes quando perpendiculares à direção de visada, porém, não são detectáveis quando possuem orientação paralela ao raio do radar.

2.3.3.5 Penetração dos sinais de radar

Em geral os sinais de radar podem penetrar em muitos meios considerados “sólidos” por radiações de outros comprimentos de onda, incluindo-se a vegetação de cobertura dos solos e a própria superfície do terreno. Não há meios claramente definidos para se reconhecer a existência de penetração e separar seus efeitos das muitas outras variáveis que contribuem para o retorno do sinal de radar. A penetração é conhecida como “efeito pelicular” das ondas eletromagnéticas e corresponde à profundidade do objeto onde a intensidade do sinal é reduzida em aproximadamente 37 % (CAMPBELL, 1996). Depende, também, das características do objeto e do comprimento de onda da radiação. A penetração aumenta com o comprimento de onda e na ausência de umidade; depende da rugosidade e do ângulo de incidência, sendo menor para ângulos de incidência maiores. Para o SLAR a penetração será maior na faixa de terreno mais próxima do curso da aeronave ou projeção próxima (*near range*). A radiação das bandas X e K (0,75 – 3,75 cm) é em geral retornada a partir da primeira superfície onde incidir, na maioria das vezes, a folhagem. A radiação da banda L (15 – 30,0 cm), de maior comprimento, possui maior grau de penetração, atingindo galhos, troncos e superfícies do terreno abaixo do dossel (CAMPBELL, 1996).

O comportamento espectral de cada alvo da superfície terrestre pode ser estudado através do **coeficiente de retroespalhamento** (σ°), que representa a relação entre a seção transversal do feixe radar e a área iluminada pelo sistema radar, sendo comumente medido em decibéis (dB) (FUNG e ULABY, 1983). Em termos práticos, o coeficiente de retroespalhamento é uma medida quantitativa da intensidade de energia que retorna a antena de radar (SABINS, 1997). À medida que a umidade (água absorvida) dos alvos aumenta, também aumenta o coeficiente de retroespalhamento, o que, por sua vez, produz assinaturas mais brilhantes na imagem.

2.3.3.5.1 Penetração dos sinais em relação à água

O retorno dos sinais de radar para corpos d'água é mais evidente do que para outras superfícies, sendo afetado pela frequência da onda incidente, velocidade e direção dos ventos, polarização, rugosidade da superfície líquida e ângulo de incidência. Dentre estes fatores, o ângulo de incidência é o que mais afeta o espalhamento dos sinais (FUNG e ULABY, 1983).

O aumento do ângulo de incidência e da velocidade dos ventos, segundo MOORE e FUNG (1979), provoca um aumento na variação do coeficiente de retroespalhamento: a velocidade do vento aumenta a rugosidade da superfície d'água e, conseqüentemente, o retorno dos sinais de radar. Nesse caso, a superfície d'água tende a tons de cinza menos escuros na imagem. As variações nos tons de cinza tornam-se mais evidentes para ângulos de incidência maiores. Para superfícies de águas lisas, o coeficiente de retroespalhamento é baixo (reflexão especular), ocorrendo tons de cinza mais escuros para a água. Deste modo, quanto mais rugosa for a superfície d'água, mais difuso será o retorno dos sinais na imagem, produzindo assinaturas mais claras.

A variação no retorno do sinal entre especular (escuro) e difuso (brilhante) depende das condições da superfície d'água, podendo apresentar confusão na delimitação de linhas costeiras, especialmente em ambientes em que alvos terrestres podem ter um retorno similar em termos de tonalidade e textura. Em tais situações, interpretações adequadas requerem prévio conhecimento da área. Em relação a corpos de água doce, a detecção é obtida a partir do baixo retorno do sinal quando as águas são consideradas sem turbulência, mostrando limites bem nítidos e contraste entre os alvos vizinhos no terreno. Dados obtidos com polarização HH permitem uma melhor delimitação entre água e terra do que com polarização VV (SIMONETT e DAVIS, 1983).

2.3.3.5.2 Penetração dos sinais em relação ao solo

O comportamento espectral do solo em imagens de radar, segundo FUNG e ULABY (1983), depende de vários fatores, tais como: teor de umidade, rugosidade, padrões periódicos de cultivo da terra, textura, etc. A dependência do coeficiente de retroespalhamento em termos de umidade e textura é devida à forte sensibilidade da constante dielétrica em relação ao conteúdo de água no solo, ou seja, com o aumento da umidade no solo, ocorre um aumento da constante dielétrica, logo, maior retroespalhamento dos sinais (tons mais claros na imagem). Em solos úmidos ocorre menor penetração de microondas em suas camadas inferiores, o que torna os solos secos mais aptos para maior profundidade de penetração dos sinais. Assim, a penetração dos sinais de radar na superfície varia inversamente com o valor da constante dielétrica e diretamente com o comprimento de onda.

A umidade do solo normalmente limita a penetração das ondas de radar a profundidades de poucos centímetros. No entanto, é possível observar penetração de sinal de vários metros em solos sob condições extremamente secas com o radar de banda L (LILLESAND e KIEFER, 1994).

Segundo SIMONETT e DAVIS (1983) ocorre um aumento no coeficiente de retroespalhamento com o aumento da rugosidade do solo e do teor de umidade, fazendo com que a imagem apareça em tons mais claros. Dessa forma, o retorno dos sinais em relação ao solo pode, muitas vezes, dominar a cena em áreas de agricultura, como, também, em áreas com vegetação natural.

Através de estudos sobre o coeficiente de retroespalhamento (σ°) para o solo, ULABY et al. (1974) constataram que polarizações paralelas HH e VV são úteis na determinação do teor de umidade e que solos com conteúdo de água acima de 20% podem ser melhor estudados em polarizações VV. Em pesquisas posteriores, realizadas por HIROSAWA et al. (1978), verificou-se que a sensibilidade na determinação do teor de umidade dos solos com polarizações cruzadas HV é maior do que com polarizações paralelas HH (Figura 10).

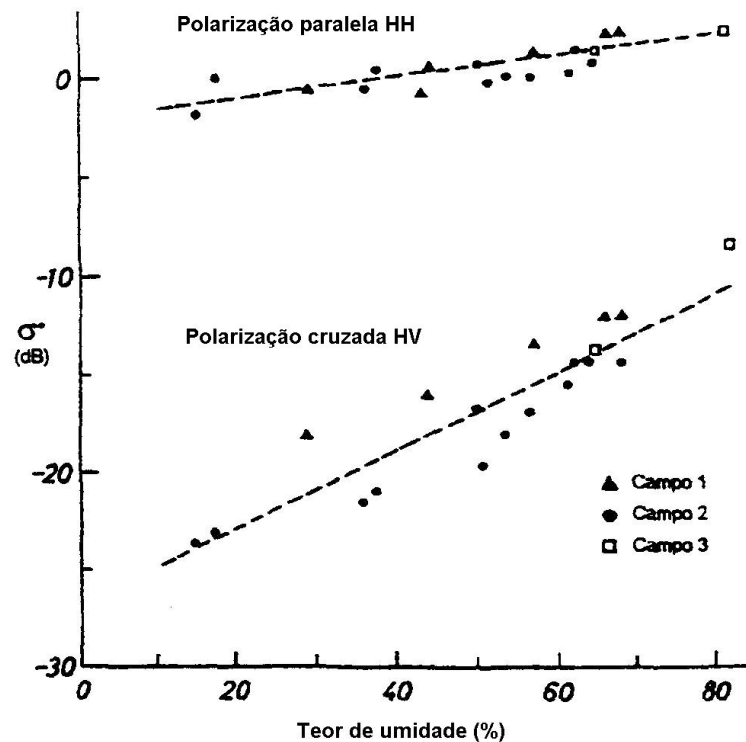


FIGURA 10 – INFLUÊNCIA DO TEOR DE UMIDADE DO SOLO NO COEFICIENTE DE RETROESPALHAMENTO

FONTE: SILVA JR. (1999)

2.3.3.5.3 Penetração dos sinais em relação à vegetação

Segundo FUNG e ULABY (1983), GUPTA (1991), AVERY e BERLIN (1992), o comportamento da vegetação em relação ao retorno dos sinais de radar varia de acordo com o teor de umidade (que controla a complexa constante dielétrica), características do dossel (geometria, espessura e tamanho de folhas, tronco, frutos, etc) e orientação dos alvos. Além disso, devem ser considerados os parâmetros do sistema, que incluem o comprimento de onda e a polarização. Na maioria dos casos, o retorno dos sinais para a vegetação deve ser visto como uma mistura das reflexões entre folhas, galhos e troncos, e em alguns casos, o próprio solo. Para pequenos comprimentos de onda, o retorno dos sinais de radar é predominantemente dado pelas folhas, em função do seu elevado teor de umidade, que tende mais a refletir do que

transmitir os sinais. Com o aumento do comprimento de onda, o retorno dos sinais sofre influência das folhas, troncos e solo, de forma que a utilização de ondas mais longas (10 a 30 cm) é melhor para a obtenção de informações a respeito de troncos e galhos de árvores (LILLESAND e KIEFER, 1994).

Em áreas com densa cobertura florestal, a reflexão é difusa e o retorno do radar é de moderado a forte, produzindo tonalidades variando de intermediárias a claras na imagem. Para esse tipo de cobertura florestal, a intensidade do sinal de retorno depende de variáveis como a densidade, a espécie (coníferas, folhosas) e a presença ou ausência de água (AVERY e BERLIN, 1992).

Para a maioria dos tipos de vegetação, a polarização HH é melhor para penetração no dossel. Além disso, a profundidade de penetração é inversamente relacionada à espessura e ao conteúdo de umidade do dossel (AVERY e BERLIN, 1992). O coeficiente de retroespalhamento, no entanto, é maior para vegetação com alto conteúdo de umidade do que para vegetação seca (LILLESAND e KIEFER, 1994).

O retorno dos sinais de radar é especialmente significativo para a agricultura, dando aos intérpretes a possibilidade de distinguir entre tipos distintos de cultivo (SIMONETT e DAVIS, 1983). BUSH e ULABY (1978) investigaram culturas de milho, soja e trigo e mostraram que a utilização de polarização paralela em ângulos de incidência entre 40° e 60° apresenta resultados com bom grau de separação entre culturas. ULABY et al.(1980) também demonstraram que o retorno dos sinais de radar em polarizações paralelas HH apresenta ótimos resultados na discriminação entre áreas de cultivo de milho e soja.

Plantações alinhadas na direção azimutal retornam mais energia do que aquelas alinhadas na direção do feixe radar, especialmente no sistema de polarização paralela (LILLESAND e KIEFER, 1994).

Na Figura 11 é apresentado um desenho esquemático sobre os sinais de retorno de radar em relação à vegetação, considerando o ângulo de incidência, em diferentes comprimentos de onda.




FIGURA 11 – PENETRAÇÃO DA RADIAÇÃO RADAR NA VEGETAÇÃO, EM FUNÇÃO DO ÂNGULO DE INCIDÊNCIA EM DIFERENTES COMPRIMENTOS DE ONDA

FONTE: Modificado de ULABY et al. (1981)

2.3.3.6 Ruído (*speckle*)

Imagens produzidas por satélites com sensor radar possuem aparência granular quando comparadas com imagens produzidas por satélites com sensor eletro-óptico. Esse fato deve-se a um ruído denominado *speckle*, que é inerente à forma de imageamento dos sistemas radar. O efeito coletivo de uma imagem SAR é a textura da cena imageada misturada com a textura *speckle* (AHERN, 1994).

O *speckle* é um ruído de efeito multiplicativo e aparece na imagem como resultado do espalhamento de sinais devido a superfícies rugosas, ou seja, superfícies que apresentam grandes irregularidades com relação ao comprimento de onda usado no imageamento (CRACKNELL e HAYES, 1993). A presença deste tipo de ruído

dificulta a interpretação visual, bem como a classificação automática de imagens de radar (MASCARENHAS, 1997).

As ondas emitidas pela antena dos sistemas radares são chamadas coerentes, pois se propagam em fase e interagem de forma mínima no seu trajeto até a superfície. Porém após interação com o alvo, essas ondas não se encontram mais em fase, principalmente devido às diferentes distâncias que elas percorrem a partir dos alvos (ERDAS, 1997). Quando a energia eletromagnética é retroespalhada pelo alvo imageado, ocorrem interferências aleatórias construtivas (ondas de uma célula de resolução que estão em mesma fase) e destrutivas (ondas com fases distintas de 180°), causando o *speckle* (LILLESAND e KIEFER, 1994). Essas interferências produzem, respectivamente, pontos brilhantes e pontos escuros na imagem. Assim, em áreas que apresentam homogeneidade, podem ocorrer variações nos tons de brilho de um pixel vizinho para outro (FITCH, 1988).

Uma alternativa possível para a redução do ruído *speckle* é o processamento multi-*look* (LILLESAND e KIEFER, 1994). Neste procedimento a imagem final é composta pela média de várias imagens independentes da mesma área (*looks*), produzidas empregando-se diferentes porções da abertura sintética (SPRING, 1998). Essa técnica aumenta a relação sinal-ruído da imagem final proporcionalmente à raiz quadrada do número de *looks*, diminuindo o efeito do ruído *speckle*. No entanto, a desvantagem do método está em que o tamanho da célula de resolução da imagem multi-*look* é diretamente proporcional ao número de *looks*, de forma que uma imagem de quatro *looks*, por exemplo, possuiria uma resolução quatro vezes pior do que uma imagem de um só *look*, embora a intensidade de *speckle* equivallesse à metade daquela de uma imagem de um *look* (LILLESAND e KIEFER, 1994).

Resultados melhores podem ser obtidos através da aplicação de filtros espaciais construídos para aumentar a relação “sinal-ruído” das imagens de radar, preservando os detalhes das feições e o aumento do poder de separação das classes na superfície (LEE, 1981; FROST et al., 1982; KUAN et al., 1987; RAO et al. 1995).

Em ERDAS (1997) encontram-se relacionados os principais tipos de filtros empregados no processamento de imagens de radar. Entre os filtros heurísticos – que

não consideram qualquer critério estatístico – pode-se citar o filtro de média, que é o mais simples deles e consiste na substituição do pixel de interesse (centro da janela) pela média aritmética de todos os valores dentro da janela. Nesse caso o *speckle* não é removido, porém seu efeito é distribuído no conjunto de dados. É o menos satisfatório dos filtros e possui a desvantagem de perda de resolução.

O filtro de mediana é outro filtro de concepção heurística que opera através da ordenação, em seqüência, de todos os DN's dentro da janela definida pelo usuário. O pixel de interesse é, então, substituído pelo valor do centro dessa distribuição. Ruídos de função de pulso – inerentes à pulsação das microondas – são removidos com a aplicação do filtro de mediana. No entanto, as funções de rampa e degrau são mantidas.

Segundo MASCARENHAS (1997) os filtros mais efetivos para a redução do *speckle* são adaptativos e baseados em modelos apropriados para o retorno dos sinais de radar e para as propriedades estatísticas do ruído *speckle*. O fato de que, em áreas homogêneas, o desvio-padrão é proporcional à média, sugere que o *speckle* pode ser expresso através de um modelo multiplicativo na forma:

$$Z_{i,j} = X_{i,j} \cdot n_{i,j}$$

onde:

i,j representam a posição do pixel na imagem;

z representa o valor observado com ruído do pixel;

x é o sinal original (retorno) e

n é o ruído *speckle*, com média igual a 1 e descrito por uma função de densidade de probabilidade que depende do tipo de detecção e do número de *looks*.

As variáveis x e n são independentes. Para tornar aditivo este modelo multiplicativo, pode-se logaritmar os termos, obtendo-se:

$$\log z = \log x + \log n$$

A partir daí é possível derivar uma série de filtros de redução de ruído, sendo que, no estágio final, é efetuada uma operação exponencial para obter uma estimativa da imagem original (MASCARENHAS, 1997).

Os filtros de Sigma e de Lee utilizam as distribuições estatísticas dos valores dos DN's dentro da janela móvel para estimar o valor do pixel de interesse. Geralmente são usados iterativamente, ou seja, pela análise do histograma o analista pode decidir se é necessária mais uma iteração e quais os parâmetros e tamanhos da janela a serem usados.

O coeficiente de variação ou σ é um parâmetro derivado da cena que se utiliza como parâmetro de entrada nos filtros de Sigma e Lee. Pode-se assumir que os ruídos em dados de radar seguem uma distribuição normal. Assim, para dados de radar de um *look* o valor teórico para o desvio-padrão seria de 0,52 e para dados de quatro *looks*, seria de 0,26. Os filtros de Lee se baseiam na suposição de que a média e a variância do pixel de interesse são iguais à média e variância locais de todos os pixels dentro da janela móvel. O filtro de Sigma assume que 95,5% de amostras aleatórias encontram-se dentro de uma amplitude de duas unidades de desvio-padrão (2σ). Esse filtro de supressão de ruído substitui o pixel de interesse pela média de todos os DN's dentro da janela que caem dentro deste intervalo. Geralmente os filtros Lee e Sigma podem ser usados iterativamente, ou seja, pela análise do histograma o analista pode decidir se é necessária mais uma iteração e quais os parâmetros e tamanhos da janela a serem usados.

O filtro de Frost é um algoritmo de média quadrática residual mínima adaptado às estatísticas locais da imagem, que servem como parâmetros de ponderação para a resposta do filtro. Esse algoritmo assume que o ruído é multiplicativo com estatísticas estacionárias.

O filtro de Kuan/Nathan também se baseia na média quadrática residual mínima num modelo multiplicativo. É semelhante ao filtro de Lee, porém a estimação ponto a ponto é efetuada empregando-se o filtro de Wiener (SPRING, 1998a).

MASCARENHAS (1997) observou que, na prática, os filtros de Lee e de Kuan apresentam desempenho bastante semelhante.

LEE et al. (1994) avaliaram o desempenho dos filtros em função de vários fatores: retenção do valor médio sobre áreas homogêneas, não-tendenciosidade, preservação de bordas e de feições esguias, preservação de alvos pontuais, preservação da textura, eficiência computacional e complexidade de implementação. A utilização de um determinado filtro irá depender do tipo de aplicação a que se destina a imagem de radar; cada sensor apresenta uma resposta diferente para a redução do *speckle*, por isso, a remoção desse ruído torna-se um processo iterativo. Em geral, para áreas com terrenos relativamente homogêneos usa-se um filtro de média ou mediana; para áreas em que se deseja preservar detalhes específicos com mínima perda de resolução, aplicam-se filtros adaptativos, tais como: Lee, Frost ou Kuan (RADARSAT, 1995).

Qualquer operação de processamento de imagens efetuada antes da remoção do *speckle* ocasiona uma degradação, resultando na incorporação deste à imagem. Portanto, não se deve retificá-la, corrigi-la para a distância no terreno, reamostrar, realçar ou classificar pixels antes de remover o ruído *speckle* (ERDAS, 1997).

2.3.3.7 Sistemas radares orbitais

Durante muito tempo a incompatibilidade tamanho da antena versus resolução espacial foi um obstáculo à utilização de sistemas radares em plataformas orbitais. Com o surgimento dos radares de abertura sintética (SAR) foram lançados satélites equipados com sensores de microondas, capazes de adquirir imagens com fino detalhamento espacial a grandes altitudes.

No início as principais dificuldades operacionais foram devidas à demanda de grande quantidade de energia elétrica e, também, em derivar informações das imagens obtidas. As primeiras missões experimentais com radares em satélites tiveram por objetivo a obtenção de um arquivo de imagens representativas de uma grande amplitude de terrenos com as mais diversas características para, posteriormente, poder-se desenvolver experiência na interpretação e análise de imagens.

Nas Tabelas 4 e 5 encontram-se sumarizadas as características dos principais sistemas radares em nível orbital, transportados no ônibus espacial e satelitários, em operação ou já desativados.

TABELA 4 – CARACTERÍSTICAS DAS MISSÕES DE RADAR TRANSPORTADO NO ÔNIBUS ESPACIAL

CARACTERÍSTICAS	SIR-A	SIR-B	SIR-C/X
Lançamento	1981	1984	1994
Comprimento de onda (cm)	23,5 (L)	23,5 (L)	3,0 (X) 5,7 (C) 23,5 (L)
Ângulo de depressão	40°.	30° a 75°.	Variável
Resolução espacial (m)	38	25	Variável
Polarização	HH	HH	Múltipla
Largura da faixa (km)	50	40	15 a 90
Altitude (km)	250	225	225
Latitude de cobertura	50 °.N a 50 °.S	58 °.N a 58 °. S	Polar
Nacionalidade	EUA	EUA	EUA

FONTE: Compilado de GOLDBERG e STONEY (1995), CRÓSTA e SOUZA FILHO (1997), LILLESAND e KIEFER (1994)

2.3.3.7.1 Sistema JERS

O satélite JERS-1 (*Japanese Earth Resources Satellite*), desenvolvido pela Agência Nacional de Desenvolvimento Espacial do Japão (NASDA) e programado para atuar durante dois anos, foi lançado a 11 de fevereiro de 1992 e desativado somente em 11 de outubro de 1998, quando as estações terrestres deixaram de receber o sinal. Este foi o primeiro satélite multi-sensorial, equipado com dois sensores ópticos (OPS) e um sensor de microondas (SAR). O sistema óptico, operando com 8 bandas nas regiões do visível e infravermelho do espectro e capaz de gerar pares estereoscópicos, funcionou apenas parcialmente, produzindo imagens degradadas pela falta de nitidez e por listras (SABINS, 1997). O sistema SAR, no entanto, funcionou

perfeitamente, adquirindo imagens com 18 m x 18 m de resolução e cobrindo uma faixa de 75 km no terreno. O JERS-1 possuía órbita síncrona ao sol, com uma inclinação de 98.5°, a uma altitude de 568 km. A sua periodicidade era de 44 dias, cobrindo todas as latitudes e longitudes. O sistema radar operava na banda L (23,5 cm), com polarização HH e ângulo de depressão igual a 55°. Nos seus aproximadamente seis anos e meio de operação o JERS-1 SAR gerou produtos que permitiram analisar e monitorar recursos naturais e meio ambiente e desastres naturais. Entre os exemplos mais representativos dos resultados de pesquisa alcançados através do uso desses dados estão a recuperação do potencial de minas de óleo na bacia de Turpan, na China, a avaliação sobre a real situação do desflorestamento na Floresta Amazônica e sobre o diastrofismo (deformação da crosta terrestre) causada pela atividade do vulcão Monte Iwateyama (DE COTIS, 2000).

TABELA 5 – CARACTERÍSTICAS DOS PRINCIPAIS SISTEMAS RADARES ORBITAIS

CARACTERÍSTICAS	SEASAT	ERS-1 ERS-2	JERS-1	ALMAZ	RADARSAT
Lançamento	1978	1991	1992	1991	1995
Comprimento de onda (cm)	23,5 (L)	5,7 (C)	23,5 (L)	9,6 (S)	5,6 (C)
Ângulo de depressão	70°.	67°.	55°.	40° a 58°.	31° a 80°.
Resolução espacial (m)	25	30	18	10 a 30	Variável
Polarização	HH	VV	HH	HH	HH
Largura da faixa (km)	100	100	75	Variável	50 a 500
Altitude (km)	790	785	568	360	798
Latitude de cobertura	72°N a 72°S	Polar	Polar	73°N a 73°S	Polar
Nacionalidade	EUA	Europa	Japão	Rússia	Canadá

FONTE: Compilado de GOLDBERG e STONEY (1995), CRÓSTA e SOUZA FILHO (1997), LILLESAND e KIEFER (1994)

2.4 PROCESSAMENTO DIGITAL DE IMAGENS

Processamento digital de imagens é um conjunto de procedimentos que melhoram a informação pictorial para interpretação do olho humano, bem como para o reconhecimento dos dados de uma cena pelo computador (GONZALEZ e WINTZ, 1977). A manipulação numérica de imagens digitais é efetuada através de analisadores eletrônicos que, em conjunto formam os sistemas de tratamentos de imagens (ROSA, 1995).

Segundo AVERY e BERLIN (1992) o processamento digital de imagens compreende quatro categorias principais de operações em computador: restauração de imagens ou pré-processamento, realce de imagens, classificação de imagens e fusão de dados.

2.4.1 Pré-Processamento ou Restauração de Imagens

O pré-processamento se refere àquelas operações efetuadas preliminarmente à análise principal (CAMPBELL, 1996). Também chamado de restauração de imagens, o pré-processamento tem por objetivo corrigir as distorções ou degradações oriundas do processo de aquisição da imagem. É constituído basicamente por duas operações: correção radiométrica e correção geométrica.

2.4.1.1 Correção radiométrica

As imagens originais podem apresentar degradações radiométricas em função de desajustes na calibração do sensor, de erros na transmissão de dados e de influências atmosféricas (ROSA,1995).

A correção de ruídos é fundamental para iniciar o processo de interpretação visual da imagem e evitar que dados incorretos sejam processados. Os defeitos mais comuns incluem a falha de linha (*line drop*) e o *striping*, que são de natureza sistemática. Os ruídos aleatórios são variações não sistemáticas nos níveis de cinza, de

pixel a pixel fazendo com que a imagem possua uma aparência salpicada (*salt and pepper*) (LILLESAND e KIEFER, 1994). Para a remoção dos ruídos sistemáticos são aplicados fatores de ajuste do nível de cinza aos histogramas das linhas com problema. Na falha de linha os níveis de cinza da linha precedente podem ser inseridos no lugar dos pixels defeituosos. Os ruídos aleatórios podem ser eliminados aplicando-se um filtro de média móvel à imagem (SABINS, 1997).

Outro tipo de correção radiométrica é a correção atmosférica, utilizada para reduzir os efeitos da interferência da atmosfera sobre os valores de níveis de cinza registrados em uma dada cena (NOVO, 1995).

A quantidade de correção atmosférica a ser aplicada depende dos comprimentos de ondas das bandas e das condições atmosféricas no momento de tomada da cena (SABINS, 1997). A dispersão é maior para comprimentos de ondas mais curtos e para atmosferas úmidas, com fumaça e poeira.

As técnicas para correção atmosférica envolvem a aplicação de modelos matemáticos, subtração de pixels escuros ou regressão entre bandas (ROSA, 1995).

2.4.1.2 Correção geométrica

O processo de aquisição das imagens por sensores em plataformas orbitais e não orbitais introduz algumas irregularidades geométricas que são classificadas como distorções sistemáticas e não sistemáticas.

As primeiras são aquelas cujos efeitos permanecem constantes e podem ser previstos antecipadamente. A assimetria durante a varredura, as variações na velocidade do espelho do scanner e distorções perpendiculares à órbita pertencem a esta categoria (SABINS, 1997). A correção para as distorções sistemáticas consiste na aplicação de fórmulas obtidas modelando-se as fontes das distorções matematicamente (LILLESAND e KIEFER, 1994). Os parâmetros de tais fórmulas incluem, por exemplo, a velocidade conhecida do satélite e as variações conhecidas na velocidade do espelho. A correção das distorções perpendiculares à trajetória é efetuada

empregando-se funções trigonométricas. Para a maioria das imagens de satélites as distorções sistemáticas são corrigidas antes da distribuição dos dados (SABINS, 1997).

As distorções não sistemáticas são causadas pelas variações na atitude, velocidade e altitude da aeronave, sendo, portanto, imprevisíveis. No caso do sensor TM a quantidade de rotação da terra durante os 26 segundos requeridos para a aquisição de uma cena resulta em distorções na direção do escaneamento, que, por sua vez, é função da latitude e órbita da aeronave. O processo de correção consiste em deslocar grupos sucessivos de 16 linhas em direção a oeste para compensar a rotação da terra (SABINS, 1997).

As variações na atitude e altitude da aeronave produzem distorções aleatórias que são corrigidas utilizando-se pontos de controle bem distribuídos na imagem. Pontos de controle são locais visualizados na imagem que podem ser localizados com precisão no terreno e em mapas corrigidos planimetricamente (CAMPBELL, 1996). Para que a imagem digital tenha propriedades cartográficas, é necessário que a mesma seja corrigida segundo um sistema de coordenadas pré-determinadas. O processo que possibilita que a imagem possua escala e sistema de projeção cartográfica denomina-se retificação ou correção geométrica. Na seqüência de operações para a retificação deve-se obter as coordenadas de numerosos pontos de controle referentes à sua posição na imagem (linha, coluna) e no terreno (coordenadas UTM ou de qualquer outro sistema de referência). Esses valores são então submetidos a uma análise de regressão para determinar os coeficientes de duas equações de transformação de coordenadas que podem ser usadas para interrelacionar as coordenadas geometricamente corrigidas (mapa) e as coordenadas da imagem (LILLESAND e KIEFER, 1994). Geralmente tais equações são representadas por polinômios de ordem n . Uma transformação de primeira ordem é denominada transformação linear, enquanto que transformações de segunda ordem ou mais altas são denominadas transformações não-lineares. No caso de imagens de radar recomenda-se a utilização de equações de transformação não-lineares, com polinômios de terceira ordem (ERDAS, 1997).

Assim, aplicando-se as equações de transformação, está-se definindo uma matriz de saída, geometricamente corrigida, porém de células vazias que devem ser

preenchidas com o nível de cinza do(s) pixel(s) correspondente(s) da imagem original (LILLESAND e KIEFER, 1994). Este processo é denominado reamostragem e pode ser efetuado pelos seguintes métodos (ERDAS, 1997):

- a) vizinho mais próximo – usa o valor do pixel mais próximo para atribuir o valor do pixel de saída. Oferece a vantagem da simplicidade computacional e evita a alteração dos valores dos pixels originais. Esta é uma propriedade importante no caso de dados qualitativos ou em imagens que serão submetidas a um processo de classificação automática. Porém as características na imagem de saída podem parecer espacialmente deslocadas em até 0,5 pixel, o que pode causar uma aparência descontínua na imagem corrigida, especialmente em linhas diagonais e curvas;
- b) interpolação bilinear – usa a média ponderada pela distância dos valores de quatro pixels numa janela 2 x 2 na imagem original para calcular o valor de saída através de uma função bilinear. A maior vantagem desse método é a aparência mais suavizada da imagem de saída. É utilizado freqüentemente quando há necessidade de se modificar o tamanho do pixel, como, por exemplo, na fusão de imagens de diferentes sensores. No entanto, a interpolação bilinear equivale a uma convolução de baixa freqüência, onde as bordas são suavizadas. Como os níveis de cinza da imagem são alterados, podem ocorrer problemas nas análises de reconhecimento de padrões espectrais realizadas posteriormente. LILLESAND e KIEFER (1994) recomendam que a reamostragem seja efetuada após os procedimentos de classificação das imagens;
- c) convolução cúbica - usa a média ponderada pela distância dos valores de 16 pixels numa janela 4 x 4 na imagem original para calcular o valor de saída através de uma função cúbica. O efeito produzido por uma ponderação cúbica pode tornar a imagem mais nítida e suavizar os ruídos (ATKINSON, 1985). Da mesma forma como ocorre na

interpolação bilinear, a reamostragem por convolução cúbica altera os níveis de cinza, influenciando, portanto, os procedimentos classificatórios subsequentes.

2.4.2 Realce de Imagens

O objetivo do realce de imagens é melhorar a detectabilidade de objetos ou padrões numa imagem digital, de modo a facilitar a sua interpretação visual (AVERY e BERLIN, 1992).

LILLESAND e KIEFER (1994) dividem as técnicas de realce de imagem em três categorias: manipulação de contraste, manipulação de características espaciais e manipulação multi-imagem.

2.4.2.1 Realce de contraste

O contraste é a medida do espalhamento dos níveis de cinza (CROSTA, 1993). A ampliação linear de contraste tem por objetivo realçar as feições das imagens que possuem baixo contraste, devido a fatores como a absorção atmosférica, alvos da cena, etc.

Uma das operações mais comuns na técnica de manipulação de contraste é o estabelecimento de um limiar de nível de cinza, usado para segmentar uma imagem em duas classes: uma para aqueles pixels cujos valores situam-se abaixo do limiar definido pelo analista e outra para aqueles acima deste valor. Geralmente é aplicado em imagens que apresentam histogramas bimodais. O uso do limiar permite que seja criada uma máscara binária para uma imagem (LILLESAND e KIEFER, 1994).

O fatiamento é outra técnica de realce em que os tons de cinza contínuos de uma imagem são convertidos em intervalos de densidade ou fatias, cada uma correspondendo a uma determinada amplitude de DN's.

Cada fatia digital é apresentada com uma cor individual ou então delimitada por linhas de contorno.

O aumento de contraste propriamente dito modifica a escala de cinza para produzir uma imagem mais facilmente interpretável. Geralmente as imagens brutas dos sensores orbitais aparecem escuras e com falta de contraste. A redistribuição dos níveis de cinza pode ser efetuada aplicando-se funções de transferência de contraste lineares (saturado ou não-saturado) ou não-lineares (p. e., normalização e equalização do histograma). No aumento linear de contraste (Figura 12) a função de transferência é uma reta e apenas dois parâmetros são controlados: a inclinação e o intercepto. As funções de transferência não-lineares, como a normalização do histograma, forçam uma distribuição de frequência assimétrica dos dados originais a assumir a forma de uma distribuição normal ou não-assimétrica. Para evitar a subjetividade do realce de contraste que varia de pessoa para pessoa, SOUSA (1996) realizou uma análise estatística das imagens, antes e depois da aplicação da técnica e observou que, trabalhando com valores de média e desvio-padrão, pode-se eliminar a subjetividade do realce da cena, ou seja, com uma média em torno de 127 e um desvio-padrão na faixa de 40 a 50, pode-se ter bons resultados nesse processo.

2.4.2.2 Processamento de características espaciais

Os filtros espaciais têm a finalidade de acentuar ou suavizar dados de imagem de várias frequências espaciais. Áreas de alta frequência espacial são aquelas em que os níveis de cinza se alteram abruptamente num número relativamente pequeno de pixels, definindo áreas “rugosas” ou os detalhes de uma imagem. Já em área de baixa frequência espacial os níveis de cinza variam gradualmente sobre um número relativamente grande de pixels. Na Figura 13 encontram-se exemplificados aspectos de áreas de frequência espacial alta, baixa ou zero. Nas áreas de frequência espacial igual a zero a imagem apresenta-se plana, com todos os pixels com o mesmo valor; para baixas frequências, a imagem consiste de uma escala de níveis de cinza variando gradativamente; para frequências altas, a imagem assume um aspecto de “tabuleiro de xadrez”, com pixels brancos e pretos.




FIGURA 12 – AMPLIAÇÃO LINEAR DE CONTRASTE

FONTE: CRÓSTA (1993)




FIGURA 13 – FREQUÊNCIAS ESPACIAIS

FONTE: Adaptado de ERDAS (1997)

A aplicação de filtros espaciais altera, portanto a aparência textural da imagem (AVERY e BERLIN, 1992). Assim os filtros passa-alta permitem a passagem de altas frequências, enfatizando os detalhes de uma imagem. De maneira oposta os filtros passa-baixa produzem a suavização da imagem, suprimindo as altas frequências

espaciais. A aplicação dos filtros consiste na movimentação de uma sub-matriz, denominada “janela”, de N por M pixels através da imagem original. Os filtros podem ser, ainda, classificados em filtros direcionais ou não-direcionais (filtros Laplacianos).

Filtros de realce de bordas são aqueles em que se procura preservar tanto o contraste local quanto a informação dos níveis de cinza de baixa frequência, o que não acontece quando se utiliza filtros passa-alta (LILLESAND e KIEFER, 1994). Uma borda pode ser um limite separando diferentes feições ou uma linha que difere das feições presentes em ambos os seus lados. O realce de bordas possui o efeito de produzir uma imagem mais nítida porque a informação de alta frequência é acentuada pela filtragem passa-alta (AVERY e BERLIN, 1992).

Como alternativa às manipulações de características espaciais – implementadas no domínio espacial – pode-se utilizar o espaço de coordenadas no domínio da frequência. A operação matemática em que uma imagem é separada em suas várias componentes de frequência espacial é conhecida como uma transformação de FOURIER (LILLESAND e KIEFER, 1994). Trata-se do ajuste de uma função contínua através dos valores discretos dos DN's plotados ao longo de cada linha e coluna na imagem.

2.4.2.3 Processamento multi-imagem

A operação de razão entre bandas consiste em dividir o valor do DN de uma banda espectral pelo valor correspondente do DN em outra banda. A razão entre bandas de imagens multiespectrais realça diferenças sutis de cor ou de reflectância espectral entre materiais de superfície que dificilmente são detectadas em imagens padrão (p.e. imagens de banda única ou composições coloridas) (AVERY e BERLIN, 1992). A operação de razão de bandas pode remover efeitos de ganho provenientes de variações espaciais ou temporais quando ocorrem em bandas de uma mesma imagem (SPRING, 1998). Como as diferenças nas condições de iluminação são minimizadas em imagens-razão, outro efeito indesejável é a supressão da expressão de topografia (SABINS, 1997). A remoção de ruído é uma etapa importante a ser executada na

preparação de imagens-razão, uma vez que a razão entre bandas realça os padrões de ruído que são não-correlacionados nas imagens componentes (LILLESAND e KIEFER, 1994).

A razão entre bandas é uma operação bastante utilizada na determinação dos índices de biomassa ou de vegetação (CRÓSTA, 1993). A razão de uma banda na região do infravermelho (IV) próximo por uma banda na região do vermelho pode ser útil na diferenciação entre áreas de vegetação submetidas ou não a estresse fisiológico. Isso se deve ao fato de que a razão IVPróximo / Vermelho para a vegetação sadia é alta, enquanto que a mesma razão para a vegetação estressada é tipicamente baixa, pois a reflectância no infravermelho decresce e a no vermelho, aumenta (LILLESAND e KIEFER, 1994). MATHER (1999) recomenda que a imagem em níveis de cinza resultante dessa razão de bandas seja submetida a um filtro passa-baixa e, depois, seja “fatiada” em diversos tons, com o intuito de proporcionar uma impressão visual da variação em biomassa e em índice de área foliar.

Razões mais complexas envolvem somas e diferenças entre bandas espectrais, tais como o Índice de Vegetação da Diferença Normalizada (NDVI), que, segundo AVERY e BERLIN (1992), pode ser definido através da seguinte equação geral:

$$\text{NDVI} = \frac{\text{banda IVpróximo} - \text{banda vermelho}}{\text{banda IVpróximo} + \text{banda vermelho}}$$

Para o sensor Landsat 5 TM a equação apresenta a seguinte forma:

$$\text{NDVI} = \frac{\text{banda 4} - \text{banda 3}}{\text{banda 4} + \text{banda 3}}$$

Na interpretação da imagem resultante, tons mais claros estão associados a coberturas densas de vegetação sadia.

Outras técnicas de manipulação de imagens multiespectrais visam reduzir a redundância de informações espectrais presentes nas diferentes bandas. Na transformação por componentes principais é efetuada uma combinação linear dos

valores dos pixels no sistema de coordenadas original, obtendo-se um novo conjunto de variáveis transformadas, denominadas componentes, em que cada componente é não-correlacionada às demais. Geometricamente as componentes representam um conjunto de eixos ortogonais e mutuamente independentes que são ajustados aos dados originais de tal forma que o primeiro eixo contenha a maior proporção da variância total (AVERY e BERLIN, 1992). As componentes subseqüentes são responsáveis por uma proporção progressivamente menor da variância do conjunto original de dados multiespectrais.

Para reprojeter os dados originais sobre os novos eixos das componentes principais é necessário obter coeficientes de transformação aplicados de forma linear aos valores dos pixels originais. A transformação linear requerida é derivada da matriz de covariância ou da matriz de correlação do conjunto original de dados, resultando em componentes principais não-padronizadas ou padronizadas, respectivamente (EASTMAN e FULK, 1993). A multiplicação da matriz de auto-vetores, da matriz de covariância e da matriz de auto-vetores transposta dará origem a uma matriz diagonal de covariância, cujos elementos da diagonal principal, os auto-valores λ_p , representam as variâncias das *p*-ésimas componentes principais, enquanto que os valores não-diagonais são iguais a zero e podem ser ignorados. Existem tantos auto-valores quanto o número de bandas examinadas (*n*). Os auto-vetores transpostos, por sua vez, constituem os coeficientes das componentes principais. A proporção da variância total que cada uma das componentes principais explica, $\%_p$, é obtida pela razão entre o respectivo auto-valor (λ_p) e a soma de todos os auto-valores (JENSEN, 1999):

$$\%_p = \frac{\lambda_p \times 100}{\sum_{p=1}^n \lambda_p}$$

A maior vantagem da aplicação desta técnica reside na redução da dimensionalidade dos dados, o que é fator relevante quando da aplicação de processos de classificação de imagens e também por causa dos recursos computacionais e área em disco ou memória ocupadas pelas “*n*” bandas.

A análise canônica – também denominada análise discriminante múltipla – visa aumentar a separabilidade entre categorias definidas nos dados enquanto reduz as diferenças que ocorrem dentro de uma mesma categoria. A transformação linear efetuada é tal que o primeiro eixo rotacionado (a primeira componente canônica) contenha a separabilidade máxima por categoria (AVERY e BERLIN, 1992).

Quando se dispõe de imagens adquiridas em várias bandas do espectro eletromagnético é possível combiná-las no espaço de cores RGB (vermelho, verde e azul), gerando composições coloridas normais, falsa-cor ou personalizadas. O espaço IHS é uma forma alternativa ao espaço RGB para a representação das cores. Tem-se, para o espaço IHS, que a componente I (*Intensity*) representa a intensidade, a componente H (*Hue*) o matiz e a componente S (*Saturation*) a saturação. Essas componentes podem ser analisadas e manipuladas individualmente, o que não ocorre nas bandas do espaço RGB. Na Figura 14 é apresentado um diagrama do sistema IHS (esfera das cores), no qual o eixo vertical representa a intensidade (I), o raio representa a saturação (S) e a circunferência representa o matiz (H). O eixo intensidade (I) representa as variações nos valores de brilho e vai de 0 (preto) a 255 (branco); não se associa cor a este eixo. O matiz (H) representa o comprimento de onda dominante da cor. Os valores de matiz começam no 0, mais ou menos na metade dos tons de vermelho e aumentam, no sentido anti-horário, ao redor da circunferência da esfera, até chegar em 255, adjacente ao valor 0. A saturação (S) é a representação da pureza da cor em valores numéricos, variando de 0 (no centro da esfera) a 255 (na circunferência). Assim, uma saturação equivalente a zero representa uma cor completamente impura, na qual todos os comprimentos de onda estão igualmente representados como nuances de cinza. Valores intermediários de saturação são representados por tons “pastel”, enquanto que uma saturação alta (mais próxima de 255) representa cores mais puras e mais intensas. Quando se combina 3 bandas quaisquer do sensor TM ou outros dados multiespectrais, as imagens coloridas resultantes aparecem em tons pastel, característicos da falta de saturação, mesmo que a imagem tenha sido previamente submetida a técnicas de aumento de contraste por banda individual. A sub-saturação é devida ao alto grau de correlação entre as bandas

espectrais. O problema pode ser corrigido transformando-se as três bandas da composição colorida do sistema RGB para o espaço IHS utilizando algoritmos matemáticos (LAPOLLI, 1994) que relacionam os dois espaços de cores. Obtem-se, assim, três novas bandas (I, H, S) e aplica-se um aumento linear de contraste para realçar a imagem correspondente à componente saturação, o que resultará num aumento geral do brilho da imagem. Em seguida deve-se efetuar a transformação inversa, retornando-se ao espaço RGB e formando uma nova composição colorida. A vantagem da transformação para o sistema IHS é que as propriedades coloridas de um objeto em uma imagem são descritas como sensações subjetivas de brilho, cor e pureza. A componente intensidade inclui os efeitos da topografia em regiões montanhosas; a componente matiz separa áreas de vegetação e sem vegetação; a componente saturação indica regiões com vegetação densa através de uma cor pura (SABINS, 1997). Além disso, pode-se variar cada componente IHS independentemente, sem afetar as outras componentes. A abordagem IHS também pode ser usada para representar dados espacialmente registrados de diferentes resoluções espaciais (LILLESAND e KIEFER, 1994).

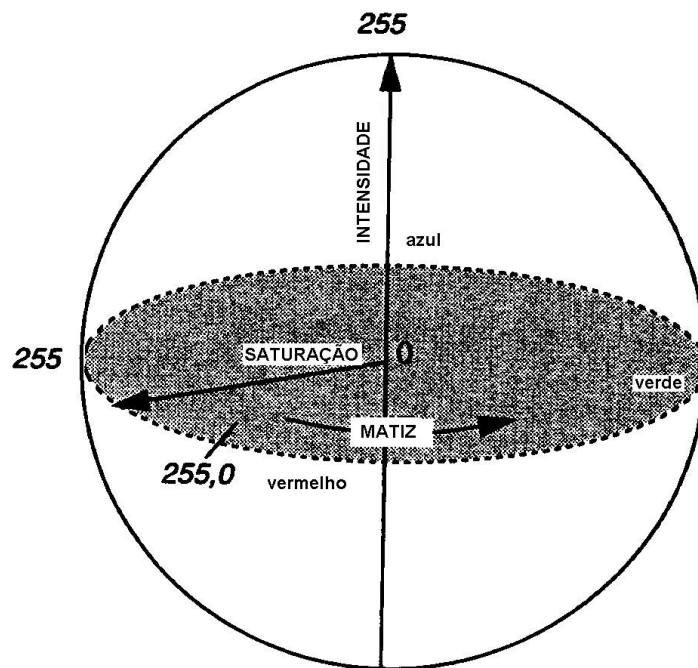


FIGURA 14 – ESFERA DAS CORES NO SISTEMA IHS

FONTE: Modificado de BUCHANAN (1979)

2.4.3 Fusão de Dados

A fusão digital de diferentes conjuntos de dados espectrais e não-espectrais permite a análise simultânea de diferentes tipos de informação para uma mesma área no terreno. Segundo AVERY e BERLIN (1992), a fusão é a superposição de imagens digitais adquiridas em diferentes comprimentos de onda, em épocas diferentes ou por diferentes sensores, além de imagens digitais representando informações de referência auxiliares tal que medições congruentes possam ser obtidas para cada pixel correspondente. Considerando-se que os conjuntos de dados a serem fundidos já se encontram em formato digital, é, então, necessário co-registrá-los de acordo com o sistema de referência comum. O registro pode ser efetuado selecionando-se uma imagem como referência e manipulando as outras de forma a coincidir com ela (técnica mestre-escravo ou *master-slave*) ou registrando todas as imagens com um mapa de referência (AVERY e BERLIN, 1992).

A fusão de imagens adquiridas por diferentes sensores pode ser utilizada para explorar os seguintes aspectos:

- a) resoluções espaciais e espectrais (p. e., imagens do satélite IKONOS nas bandas pancromática e multiespectral; imagens LANDSAT TM e SPOT pancromática; imagens LANDSAT TM e fotografias aéreas convertidas para formato digital);
- b) propriedades físicas e químicas tais como textura e rugosidade (p. e., imagens LANDSAT TM e de radar);
- c) propriedades de textura de superfície, rugosidade e inclinação local (p. e., imagens de radar).

2.4.3.1 Fusão de imagens dos sensores LANDSAT TM e SAR

O objetivo da fusão de dados SAR é explorar os diferentes conteúdos de informação sobre alvos capturados pelo SAR e por outros sensores, de forma a melhorar o reconhecimento e a discriminação de feições na cena. Isto é efetivado

realçando-se a interpretabilidade visual das feições ou melhorando-se a separabilidade entre classes em classificações numéricas. O produto final da fusão através de realce é, tipicamente, uma imagem colorida, na qual o SAR e outros dados foram combinados numa cena atrativa e facilmente interpretável. A fusão de SAR para classificação deve resultar em acurácias de classificações melhoradas para as classes de interesse (MANORE et al., 1997).

Entre as contribuições do SAR para a fusão de dados incluem-se a textura do alvo e a estrutura da forma do terreno, os indicadores de propriedades dielétricas dos alvos e uma alta confiabilidade temporal devido à sua capacidade de imageamento sob quaisquer condições atmosféricas. Em cenas de áreas com topografia suave ondulada, as imagens SAR fornecem boas informações texturais e de rugosidade de superfície sob alvos tais como variações na intemperização de rochas, estrutura do dossel da vegetação e feições de superfícies oceânicas. As contribuições de informações de outras fontes de dados incluem propriedades espectrais de alvos de dados ópticos, assinaturas de sensores infravermelho termal e dados geofísicos tais como gravidade e magnetismo. A partir de propriedades espectrais podem ser derivadas classes gerais de cobertura do solo, bem como a determinação do tipo e condições da vegetação. Outra contribuição das demais fontes de dados quando fundidas com o SAR é a melhoria da resolução. Frequentemente os dados ópticos proporcionam um efeito de maior nitidez devido aos fortes contrastes tonais entre classes dos dados ópticos quando comparados ao SAR.

A intensidade de retorno do radar é afetada pela declividade, rugosidade e cobertura vegetal. A condutividade de uma área-alvo está relacionada à porosidade do solo e ao seu conteúdo de umidade. Conseqüentemente, os dados de radar e de sensores ópticos são complementares, pois fornecem informações diferentes sobre a área de interesse (ERDAS, 1997). Uma imagem nas quais esses dois tipos de dados são combinados de forma inteligente, pode apresentar muito mais informação do que qualquer imagem isoladamente.

HARRIS et al. (1994) citam alguns fatores decisivos para o sucesso da fusão de dados:

- a) a estratégia de integração , ou seja, quais dados combinar e qual a sua apresentação, deve ser direcionada ao problema de detecção em questão;
- b) deve haver uma grande amplitude de cores no produto realçado para facilitar a interpretabilidade visual;
- c) as cores resultantes da fusão de dados devem ser interpretáveis e relacionadas às propriedades geofísicas do alvo de interesse;
- d) a efetividade da integração se baseia nas combinações espaciais e espectrais apropriadas ao problema em questão.

As técnicas de processamento de imagens para a fusão de dados incluem (HARRIS et al., 1994):

- a) combinação de bandas, que consiste em atribuir diferentes canais de dados aos canais R, G e B do equipamento para visualização. A vantagem desta técnica é a sua simplicidade e rapidez, além da facilidade de se alterar e testar um grande número de combinações. No entanto, apenas 3 canais de dados podem ser combinados e a combinação pode resultar num esquema de cores não-convencional e dificilmente interpretável. Cita-se como exemplo:

SAR → R (vermelho)

TM4 → G (verde)

TM3 → B (azul)

- b) combinações aritméticas, que envolvem a combinação de vários canais de dados através de operações aritméticas tais como diferenças, razões e diferenças normalizadas. Na maioria dos casos os dados de SAR não são combinados diretamente com dados ópticos, mas, sim, combinações de SAR e outros dados são combinados e visualizados em combinações de bandas coloridas. Um exemplo de tal combinação seria:

SAR (HH/VV) \rightarrow R
 TM4 \rightarrow G
 TM5 – TM3 \rightarrow B

As vantagens das combinações aritméticas, além da sua simplicidade e rapidez computacionais, é que elas permitem a integração de mais de 3 canais. Contudo, a desvantagem desta abordagem é a interpretabilidade de um esquema de cores não-convencional, que pode resultar do processo. POHL (1996) cita, ainda a transformação de Brovey, em que as 3 bandas TM utilizadas numa composição RGB são normalizadas, e o resultado é multiplicado pelo DN da imagem de maior resolução, para adicionar a componente de intensidade ou brilho à imagem. A vantagem desta transformação é que ela preserva a informação espectral, ao mesmo tempo em que confere maior nitidez à cena.

c) Transformações estatísticas que envolvem a transformação dos canais originais de dados em novos eixos de medição, de forma a maximizar a variância inerente aos dados no menor número possível de canais não-correlacionados. A transformação estatística mais comum é a análise por componentes principais. Quando empregada para a fusão de dados SAR, os dados ópticos são transformados para reduzir o número de feições não-correlacionadas e, então, combinados com o SAR numa composição colorida de bandas, tal como:


TM1		SAR	\rightarrow R
TM2			\rightarrow G
TM3	\Rightarrow	CP2	\rightarrow B
TM4		CP3	
TM5		CP4	
TM7			

↑

Transformação por Componentes
 Principais (CP)

Nesse caso, 6 bandas ópticas do LANDSAT TM são reduzidas a 4 componentes, das quais as duas primeiras são usadas numa combinação de bandas com dados SAR. Em muitas cenas, as duas primeiras componentes podem ser responsáveis por 60% a 80% da variância dentro da cena, o que representa uma significativa redução nos dados.

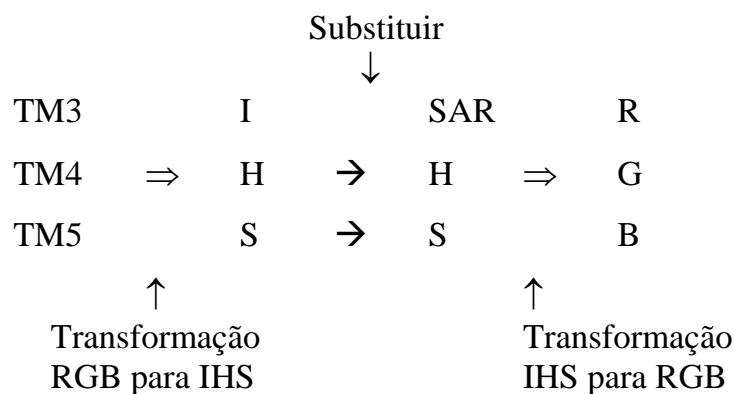
Menos comum é a inclusão de dados SAR (ou múltiplas imagens SAR) numa transformação estatística com dados ópticos, conforme segue:



As vantagens das transformações estatísticas é que elas permitem a integração de muitos canais de dados, ao mesmo tempo em que reduzem o conteúdo de informações dos dados originais a um pequeno número de canais para visualização ou classificação. As desvantagens desse processo incluem cores não-convencionais que podem resultar na visualização e a dificuldade de relacioná-las aos parâmetros geofísicos medidos no conjunto original de dados. Além disso, as transformações estatísticas são normalmente baseadas em estatísticas da cena e, portanto, difíceis de se reproduzir com diferentes cenas de entrada.

- d) Transformações no espaço de cores, que projetam a informação de cores representada no espaço RGB num conjunto diferente de eixos de medição (p.e., espaço IHS) para descrever a amplitude de possíveis variações em

tons de cores e, então, aplicar a transformação reversa. O uso de transformações no espaço de cores para a fusão de dados SAR se aproveita do fato de que a imagem SAR de único canal é acromática (sem informação de cores) enquanto que a contribuição de outras fontes de dados é tipicamente espectral, como as imagens LANDSAT TM. Um dos resultados da transformação de imagens para o espaço de cores IHS é que toda a informação de brilho é isolada no eixo de intensidade acromático. Toda a informação de cores da cena original é virtualmente capturada nos eixos de matiz e saturação. A técnica mais comum para usar a transformação IHS para a integração de dados SAR envolve a substituição destes pela informação de intensidade a partir da cena original e, então aplicar a transformação inversa, retornando os dados ao espaço RGB. Assim, trata-se de um processo efetuado em dois estágios:



Nesse processo uma combinação original de bandas que possui apresentação de cores desejável é transformada do espaço RGB para o espaço IHS. O canal intensidade é substituído pela imagem SAR e os dados são retransformados aos canais RGB para visualização. Uma das vantagens deste método é que a imagem SAR é inserida nos canais RGB resultantes, retendo, ao mesmo tempo, as cores da combinação original de bandas. Isso permite maior facilidade na interpretação devido à familiaridade com as cores e à sua relação com as propriedades geofísicas dos alvos. Além disso, ao empregar a transformação IHS, o usuário pode controlar o grau de

visibilidade da imagem SAR no produto resultante através da manipulação do parâmetro saturação (HARRIS et al., 1994).

MANORE et al. (1997) citam como desvantagens das transformações no espaço de cores para a fusão de dados, a sua complexidade computacional e conceitual, a dificuldade de se obter um produto atrativo e satisfatório e a possível perda de informação sobre alvos que são altamente correlacionados nos 3 canais da combinação original de bandas. Essas feições aparecem acromáticas na imagem original, sendo, portanto, capturadas no canal acromático (intensidade) do espaço IHS. Quando substituída pela imagem SAR a informação do canal intensidade é descartada, incluindo-se aí, a informação sobre alvos correlacionados. Mecanismos para superar este problema envolvem a combinação aritmética do canal intensidade com a imagem SAR ou a substituição de um canal diferente do espaço IHS pela imagem SAR. KUX et al. (1995) sugerem que o canal matiz seja substituído pela imagem SAR, cujo retorno determina a componente colorida da imagem de saída, enquanto que o brilho (intensidade acromática) dos dados originais é mantida.

2.4.4 Classificação de Imagens

A análise automática digital ou classificação de imagens é um processo de extração de informações que envolve a aplicação da teoria de reconhecimento de padrões a imagens multiespectrais (AVERY e BERLIN, 1992). Em termos práticos, a classificação de imagens analisa as propriedades espectrais de várias feições presentes numa imagem multiespectral e classifica os dados espectrais em categorias espectralmente similares, utilizando regras de decisão numérica pré-definidas. Outra abordagem consiste na utilização de classificadores por regiões, que empregam, além da informação espectral de cada pixel, a informação espacial que envolve a relação entre os pixels e seus vizinhos (SPRING, 1998a).

Em ERDAS (1997), a classificação multiespectral é definida como o processo de classificar pixels em um número finito de classes individuais ou categorias de dados

baseando-se nos seus valores de níveis de cinza. Se um pixel satisfaz um determinado conjunto de critérios, o pixel é atribuído à classe que corresponde àqueles critérios. O processo de classificação se divide em duas partes: o treinamento e a classificação propriamente dita (usando uma regra de decisão). Primeiramente o sistema computacional deve ser treinado para reconhecer padrões nos dados. Treinamento é o processo de definição dos critérios pelos quais esses padrões são reconhecidos (HORD, 1982). Pode ser efetuado através de método não-supervisionado ou supervisionado.

2.4.4.1 Treinamento não-supervisionado

No treinamento não-supervisionado não são utilizados dados de treinamento como base para a classificação. O usuário interage apenas no sentido de especificar alguns parâmetros que o computador usa para descobrir padrões estatísticos que são inerentes aos dados. O algoritmo de grupamento analisa os pixels “desconhecidos” na base de dados e os divide em um determinado número de classes espectralmente distintas, baseando-se nos seus grupamentos naturais (AVERY e BERLIN, 1992). A noção da existência desses grupamentos dentro de uma cena pode não ser intuitivamente óbvia, contudo pode-se demonstrar que as imagens de sensoriamento remoto são geralmente compostas de classes espectrais que, internamente, são razoavelmente uniformes com respeito aos valores de brilho em vários canais espectrais (CAMPBELL, 1996).

Os algoritmos de *clustering* ou de grupamento mais comuns são o “K-médias” e o Isodata. Na abordagem “K- médias”, o analista define o número de classes a serem estabelecidas nos dados. O algoritmo, então, determina, arbitrariamente, um vetor de médias inicial (“semente”) no espaço de medições multidimensional para cada *cluster* (LILLESAND e KIEFER, 1994; SCHOWENGERDT, 1997). Em seguida cada pixel na imagem é atribuído ao grupo cujo vetor de médias arbitrário está mais próximo. Depois de todos os pixels serem classificados desta maneira, são calculados novos vetores de média para cada um dos *clusters*. As novas médias são, então, usadas

como base para reclassificar os dados da imagem. O procedimento continua até que não haja alterações significativas na localização dos vetores de média de cada classe entre sucessivas iterações do algoritmo. Atingido este ponto o analista atribui legendas às classes espectrais formadas para a geração do mapa final.

O algoritmo Isodata é uma variação do “K-médias” e inclui a combinação de *clusters* se a sua separação estiver abaixo de um limiar pré-estabelecido ou a subdivisão de *clusters* se estes forem muito grandes (SCHOWENGERDT, 1997).

2.4.4.2 Treinamento supervisionado

No treinamento supervisionado o analista seleciona pixels que representam padrões ou feições de cobertura do solo que ele reconhece ou que podem ser identificadas com a ajuda de outras fontes, tais como fotos aéreas, verdade de campo ou mapas (ERDAS, 1997). É necessário um conhecimento prévio dos dados e das classes desejadas. A área de treinamento deve ser uma amostra homogênea da classe respectiva, porém, ao mesmo tempo deve incluir toda a amplitude de variabilidade para aquela classe (SCHOWENGERDT, 1997). Por isso sempre é utilizada mais de uma amostra de treinamento por classe. Ao identificar os padrões o usuário está “treinando” o sistema para identificar pixels com características similares.

Com relação ao número de unidades de amostra de treinamento necessárias para efetuar uma classificação supervisionada, VENTURIERI e SANTOS (1998) salientam que as amostras devem refletir a variabilidade de cada categoria dentro da área de estudo. RICHARD (1986) sugere um mínimo de $(N+1)$ unidades de amostra para representar cada classe que está sendo supervisionada, sendo N o número de bandas que compõe a imagem. Para regiões tropicais, a experiência adquirida por VENTURIERI e SANTOS (1998) em classificação supervisionada de temas agrícolas e florestais recomenda um número mínimo de $3N$ unidades de amostras para cada classe.

Quanto ao tamanho das unidades de amostra, podem ocorrer classes com áreas pequenas e espacialmente espalhadas por toda a imagem. Neste caso deve-se reduzir

ao máximo o tamanho das unidades de amostra de treinamento para até 4 pixels, evitando com isto o efeito de bordas e tornando mais fidedigno o conjunto de valores espectrais que define a classe. Esse tamanho mínimo de amostra é válido apenas se os membros individuais da amostra de treinamento são independentes. Geralmente pixels adjacentes não são independentes, apresentando o que se denomina *autocorrelação espacial*. Como consequência, as estimativas de médias e variâncias de cada feição considerada serão tendenciosas (MATHER, 1999). CAMPBELL (1996) afirma que amostras de treinamento coletadas em blocos contíguos tendem a subestimar a variabilidade dentro de cada classe e a superestimar o grau de distinção entre categorias. Dessa forma é aconselhável usar um grande número de amostras pequenas ao invés de um pequeno número de amostras grandes.

Para classificações de temas agroflorestais, que normalmente ocupam grandes extensões de áreas contíguas e sem variações radiométricas, o analista pode utilizar unidades de amostra de treinamento com tamanho próximo a 16 pixels (VENTURIERI e SANTOS, 1998). Estes mesmos autores recomendam, ainda, o uso de algum programa que avalie o desempenho de cada unidade de amostra de treinamento em relação às demais e ao conjunto de classes estudadas. É importante que o conjunto de amostras para cada classe apresente uma distribuição unimodal de frequência (CAMPBELL, 1996).

2.4.4.3 Treinamento híbrido

O treinamento supervisionado nem sempre resulta em assinaturas de classe numericamente separáveis no espaço de atributos. Por outro lado, o treinamento não-supervisionado não necessariamente resulta em classes significativas para o analista. Nesse caso, uma abordagem combinada dos treinamentos supervisionado e não-supervisionado possui o potencial de satisfazer a ambos os quesitos e pode produzir ótimos resultados, especialmente com grandes conjuntos de dados (ERDAS, 1997).

SCHOWENGERDT (1997) descreve as principais etapas de um treinamento híbrido:

- a) Aplicação de um treinamento não-supervisionado aos dados e geração de um mapa de *clusters* não-legendados. Tipicamente um grande número de *clusters* (cerca de 50) é utilizado para assegurar uma representatividade adequada dos dados.
- b) Análise e comparação do mapa gerado com levantamentos de campo e outros dados auxiliares, como fotografias aéreas, mapas temáticos, etc. São atribuídas legendas aos *clusters*. Normalmente alguns deles precisam ser subdivididos ou agrupados para fazer esta correspondência.
- c) Os *clusters* legendados são, então, empregados como amostras de treinamento numa classificação supervisionada.

2.4.4.4 Assinaturas espectrais

A similaridade entre pixels ou grupos de pixels é um conceito fundamental para os algoritmos de processamento de imagens, pois as assinaturas de classes representam agrupamentos de dados com características similares. Por outro lado, a separabilidade entre classes é determinada em função de medidas de distância, como, por exemplo, a distância Euclidiana, a de Mahalanobis, a de Bhattacharyya e a de Jeffries-Matusita (SCHOWENGERDT, 1997). As medidas de distância são aplicadas sempre entre duas distribuições no espaço de atributos.

O resultado do treinamento é um conjunto de assinaturas que define uma amostra de treinamento ou *cluster* (ERDAS, 1997). Cada assinatura corresponde a uma classe e é usada com uma regra de decisão para atribuir os pixels da imagem a uma classe. As assinaturas subdividem-se em paramétricas e não-paramétricas (SCHOWENGERDT, 1997).

Uma assinatura paramétrica é aquela que se baseia em parâmetros estatísticos dos pixels existentes na amostra de treinamento ou *cluster*. Os algoritmos paramétricos assumem alguma suposição sob a forma de distribuição de probabilidade dos níveis de cinza para cada classe. São requeridas, neste caso, as estimativas dos parâmetros da distribuição tais como o vetor das médias e a matriz de covariância. Uma das

vantagens da classificação paramétrica é a possibilidade de se estimar teoricamente o erro do classificador a partir da distribuição considerada (SCHOWENGERDT, 1997). Tanto o treinamento supervisionado como não-supervisionado pode gerar assinaturas paramétricas. Um conjunto de assinaturas paramétricas pode ser usado para treinar um classificador que se baseia em estatísticas (p.e., máxima verossimilhança) para definir as classes (ERDAS, 1997).

Os algoritmos não-paramétricos não supõem nenhuma distribuição de probabilidade e são considerados robustos porque podem funcionar bem para uma grande variedade de distribuições de classes, desde que as assinaturas de classes sejam razoavelmente distintas (SCHOWENGERDT, 1997). Uma assinatura não-paramétrica baseia-se em objetos discretos (polígonos ou retângulos) na imagem que representa o espaço de atributos (ERDAS, 1997). Esses objetos são usados para definir os limites para as classes. Um classificador não-paramétrico usará um conjunto de assinaturas não-paramétricas para atribuir pixels a uma determinada classe baseando-se em suas localizações ou dentro ou fora da área no espaço de atributos.

Quando tanto as assinaturas paramétricas como as não-paramétricas são usadas para classificar uma imagem, o usuário torna-se mais capaz de analisar e visualizar as definições de classes do que aquelas que cada tipo de assinatura fornece independentemente (KLOER, 1994).

Depois de definidas as assinaturas, os pixels da imagem são atribuídos às classes baseadas nas assinaturas, empregando-se uma regra de decisão para a classificação. A regra de decisão é um algoritmo matemático que, usando os dados contidos na assinatura, efetivamente executa a classificação dos pixels em distintos valores de classe.

2.4.4.5 Algoritmos paramétricos de classificação

Uma regra de decisão paramétrica é treinada por assinaturas paramétricas que, por sua vez, são definidas pelo vetor de médias e pela matriz de covariância dos valores dos pixels nas assinaturas. Quando se utiliza uma regra de decisão paramétrica

cada pixel é atribuído a uma determinada classe, uma vez que o espaço de decisão paramétrico é contínuo (KLOER, 1994). Entre os vários algoritmos paramétricos existentes, destacam-se o método da distância mínima, da distância de Mahalanobis e o da máxima verossimilhança (ERDAS, 1997; LILLESAND e KIEFER, 1994; CAMPBELL, 1996; ENVI, 1998).

Uma das estratégias de classificação mais simples é a regra de decisão da distância mínima, também denominada distância espectral. Primeiramente, calcula-se o valor espectral médio em cada banda para cada categoria. O conjunto desses valores constitui o vetor de médias para cada classe. O pixel desconhecido pode ser classificado computando-se a distância entre o seu valor e aquele das médias das categorias. Em seguida o pixel é atribuído à classe mais próxima. A equação que classifica pixels pela distância espectral baseia-se na fórmula da distância Euclidiana (SWAIN e DAVIS, 1978):

$$SD_{xyc} = \sqrt{\sum_{i=1}^n (\mu_{ci} - X_{xyi})^2}$$

em que:

n = número de bandas (dimensões)

i = banda considerada

c = classe considerada

X_{xyi} = nível de cinza do pixel de coordenadas x,y na banda i

μ_{ci} = média dos níveis de cinza da banda i para a amostra da classe c

SD_{xyc} = distância espectral do pixel de coordenadas x,y à média da classe c

Embora matematicamente simples (LILLESAND e KIEFER, 1994) e computacionalmente eficiente, o método da distância mínima apresenta certas limitações. A mais importante é o fato de ser insensível a diferentes graus de variância nos dados de resposta espectral.

O método da distância de Mahalanobis é similar ao da distância mínima, exceto pelo fato de empregar a matriz de covariância na equação (ERDAS, 1997). O pixel será atribuído à classe para qual a medida da distância for menor.

O tempo computacional exigido por este método é maior do que para o método da distância mínima. Por ser um algoritmo paramétrico, baseia-se, em grande parte, numa distribuição normal dos dados para cada banda. A regra de decisão de Mahalanobis pode ser mais útil do que o da distância mínima nos casos em que critérios estatísticos (como a matriz de covariância) precisam ser levados em consideração, mas onde os fatores de ponderação disponíveis no método da máxima verossimilhança não são exigidos (ERDAS, 1997).

Outro algoritmo paramétrico de classificação é aquele que faz uso da distância de Bhattacharyya como medida de separabilidade entre as distribuições (Gaussianas) associadas a cada classe (SANT'ANNA et al., 1997). No entanto este é um classificador por regiões, que parte de um particionamento prévio da imagem efetuado através de um processo denominado segmentação (v. item 2.4.4.7). Segundo MOREIRA (2001), esse classificador usa as regiões criadas na segmentação para estimar a função de densidade de probabilidade para as classes apontadas no treinamento. Em seguida, avalia, para cada região, a distância de Bhattacharyya entre as classes. A classe que apresentar a menor distância será atribuída à região avaliada.

A regra de decisão de máxima verossimilhança baseia-se na probabilidade de que um pixel pertença a uma determinada classe. Se houver um número suficientemente grande de amostras de treinamento representativas à disposição em cada classe, pode-se calcular os histogramas de classe e usá-los como aproximações das funções contínuas de densidade de probabilidade de uma amostra infinita (SCHOWENGERDT, 1997). Na prática isto significa usar os dados das amostras de treinamento para estimar médias e variâncias das classes, que, por sua vez, serão usadas para estimar as probabilidades (CAMPBELL, 1996). A regra de Bayes, que constitui a base da classificação por máxima verossimilhança estabelece as relações entre probabilidades condicionais. Na classificação de imagens de sensoriamento remoto deseja-se estimar $p(i|f)$, ou seja, a probabilidade p de um pixel pertencer a uma

determinada classe i , dado que ele apresenta um vetor de níveis de cinza f , considerando as várias bandas na cena (SCHOWENGERDT, 1997):

$$p(i|f) = \frac{p(f|i)p(i)}{p(f)} \quad \text{onde: } p(f) = \sum p(f|i)p(i)$$

sendo:

$p(i)$ = probabilidade a priori (ou peso) de ocorrer a classe i

$p(f|i)$ = probabilidade do pixel apresentar um vetor de níveis de cinza f dado que ele pertence à classe i

O pixel será atribuído à classe mais provável, isto é, àquela que possui o valor mais alto para probabilidade. Uma das desvantagens deste classificador é o maior tempo computacional, que aumenta conforme o número de bandas. É aconselhável a utilização de algum método que reduza a dimensionalidade do conjunto de dados (p.e., transformação por componentes principais), reduzindo, também, dessa forma, a complexidade dos cálculos requeridos (LILLESAND e KIEFER, 1994).

A aplicação da regra de Bayes é especialmente efetiva quando as classes são indistintas ou se sobrepõe no espaço de dados espectrais. No entanto, a adequada seleção das amostras de treinamento é condição fundamental para uma classificação acurada. No caso multidimensional, com várias bandas espectrais é necessário estimar, para cada classe, um nível de cinza médio por banda e uma matriz de variância-covariância contendo a variabilidade de cada banda e seus relacionamentos com outras bandas. Esses dados são então extrapolados para estimar médias, variâncias e covariâncias para classes inteiras, assumindo-se que os dados sejam caracterizados por distribuições de frequências normais multivariadas.

A noção de dependência espacial é útil quando incorporada num esquema Bayesiano de processamento de imagens. O algoritmo paramétrico ICM (*Iterated Conditional Modes*) é um classificador contextual Markoviano, ou seja, incorpora a noção de dependência espacial entre classes e/ou observações, dadas as classes

(FRERY, 1993). Ele se baseia na substituição da classe associada a cada coordenada por aquela classe que maximiza a distribuição *a posteriori* da classe, dadas a radiometria (componente de máxima verossimilhança) e as classes vizinhas (componente de contexto) (SANT'ANNA et al., 1997).

Em SPRING (1998a) é apresentada uma combinação do classificador de máxima verossimilhança com o classificador ICM. Numa primeira fase, são atribuídas classes aos pixels segundo a regra de decisão Bayesiana, considerando os valores de níveis de cinza. Na fase seguinte, leva-se em conta a informação contextual da imagem, sendo que a classe atribuída depende não apenas do valor observado nesse pixel, mas, também, das classes atribuídas aos seus vizinhos. O algoritmo atribui classes a um determinado pixel, considerando a vizinhança iterativamente. O processo é finalizado quando a percentagem de mudança (percentagem de pixels reclassificados a cada iteração) definida pelo usuário é satisfeita. Considerando a maior importância relativa das informações de contexto na interpretação de imagens SAR, VIEIRA (1996) aplicou o algoritmo ICM na classificação de imagens SAR-580 e JERS-1, obtendo índices de acurácia em média 115% superiores quando comparados às respectivas classificações pontuais empregando apenas o algoritmo de máxima verossimilhança. SANT'ANNA et al.(1997) também consideraram os resultados do algoritmo ICM superiores aos da classificação por máxima verossimilhança em imagens RADARSAT da região da Floresta Nacional do Tapajós.

2.4.4.6 Algoritmos não-paramétricos de classificação

Uma regra de decisão não-paramétrica não se baseia em estatísticas, sendo, portanto, independente das propriedades dos dados. Ela apenas determinará se o pixel está ou não localizado dentro ou fora dos limites de uma assinatura não-paramétrica (ERDAS, 1997). Os algoritmos não-paramétricos mais utilizados nos *software* de processamento de imagens são: métodos do paralelepípedo e do vizinho mais próximo e redes neurais (SCHOWENGERDT, 1997).

O método do paralelepípedo baseia-se na amplitude de valores dentro dos dados de treinamento para definir regiões num espaço de dados multidimensional (CAMPBELL, 1996). Em se tratando de uma classificação que envolva apenas duas bandas, a região definida pelos dados de treinamento assume a forma de um paralelepípedo. Os níveis de cinza do pixel “candidato” são comparados com limites inferiores e superiores, geralmente definidos em função da média de cada banda, mais ou menos uma unidade de desvio-padrão. Quando o nível de cinza do pixel se encontra dentro dos limites para cada banda numa assinatura, então o pixel é atribuído àquela classe de assinatura. Há casos em que o pixel pode estar localizado numa região de sobreposição de dois ou mais paralelepípedos. Isto ocorre porque quando as distribuições de categorias apresentam correlação ou alta covariância, estas são inadequadamente descritas por regiões de decisão retangulares (LILLESAND e KIEFER, 1994). A covariância é a tendência dos valores espectrais em variar de forma similar em duas bandas, resultando em nuvens de observações alongadas e oblíquas no diagrama de dispersão. Frequentemente os padrões de resposta espectral são altamente correlacionados, sendo a alta covariância mais uma regra do que exceção. LILLESAND e KIEFER (1994) sugerem que os problemas de pixels não classificados com o método do paralelepípedo sejam minimizados modificando-se os retângulos únicos de várias regiões de decisão para uma série de retângulos com bordas em degraus, que descrevem os limites das distribuições alongadas mais especificamente. Outra alternativa seria utilizar outro algoritmo para classificar os pixels sem legenda, empregando-se uma regra de decisão paramétrica (ERDAS, 1997; SCHOWENGERDT, 1997).

Os algoritmos classificadores que utilizam o método do vizinho mais próximo atribuem legendas aos pixels desconhecidos de acordo com as legendas dos vetores de treinamento vizinhos no espaço de atributos. Tendem a ser lentos porque as distâncias de cada pixel desconhecido aos muitos pixels de treinamento precisam ser calculadas (SCHOWENGERDT, 1997). CONWAY (1997) empregou técnicas de classificação supervisionadas, utilizando o método do vizinho mais próximo em diferentes

combinações de dados multitemporais do sensor ERS-1 SAR, com o objetivo de distinguir entre tipos florestais tropicais de estrutura aberta e fechada.

Algoritmos de redes neurais artificiais são abordagens não-paramétricas para classificação multiespectral em que os limites de decisão não são fixados por uma regra determinística aplicada ao protótipo das assinaturas de treinamento, mas, sim, são determinados num modo iterativo, minimizando o critério do erro na atribuição de legendas aos dados de treinamento (SCHOWENGERDT, 1997). Nesse sentido as redes neurais artificiais são similares aos algoritmos de *clustering* ou grupamentos.

2.4.4.7 Segmentação espacial-espectral

A classificação de pixels no espaço de atributos espectrais é independente de quaisquer relações espaciais. Alternativamente, no entanto, pode-se optar pela utilização de classificadores por regiões, numa abordagem denominada segmentação espacial-espectral, que incorpora ambos os tipos de informação num treinamento não-supervisionado (SCHOWENGERDT, 1997). O processo de segmentação consiste numa etapa prévia à classificação temática, onde os elementos analisados e utilizados na classificação serão as regiões resultantes da aplicação do segmentador (VENTURIERI e SANTOS, 1998). Os segmentadores simulam o comportamento do fotointérprete ao reconhecer áreas homogêneas na imagem, baseando-se em suas propriedades espectrais e espaciais (SPRING, 1998). SCHOWENGERDT (1997) relaciona alguns dos principais algoritmos de segmentação, entre eles o ECHO, AMOEBA e o SMAP. A maioria deles emprega alguma operação de gradiente local para detectar limites de regiões (detecção de bordas) ou agrega pixels vizinhos, similares, formando regiões maiores (crescimento de regiões) (SCHOWENGERDT, 1997). A conectividade espacial (de 4 ou de 8 pixels) é utilizada para agrupar pixels semelhantes em uma região da imagem que representa uma região física de propriedades similares na superfície do terreno. Assim, é necessário que o analista especifique um limiar de similaridade entre um pixel e seus vizinhos; se a diferença entre eles estiver dentro do limiar, eles serão agrupados e tratados como uma entidade

comum nas etapas subseqüentes do processamento. Do contrário, eles serão mantidos como pixels individuais. O limiar é fornecido como um valor de diferença entre níveis de cinza: para um limiar pequeno de nível de cinza, o grau de agregação em regiões é pequeno, ou seja, regiões que possuem pequena variância espectral apresentarão fragmentação excessiva, o que dificulta a interpretação e o delineamento de contornos na imagem (VENTURIERI e SANTOS, 1998); à medida que o limiar aumenta, ocorre mais agregação, e, como conseqüência, são formadas menos regiões.

No método de detecção de bordas, o algoritmo procura por descontinuidades espectro-texturais na imagem e efetua o cálculo da probabilidade de cada pixel pertencer a uma determinada borda; posteriormente, esses pixels são ligados para formação de bordas contínuas.

A existência de segmentos permite que regiões sejam classificadas utilizando toda a população de pixels dentro do segmento considerado. Isto é particularmente importante para imagens provenientes de sensores SAR, em que o *speckle* causa grande variabilidade na medição de pixels individuais (QUEGAN, 1997). Esse mesmo autor testou os algoritmos de segmentação denominados ANNEAL e RWSEG para a classificação e monitoramento de áreas agrícolas e florestais na Amazônia brasileira, empregando imagens SAR do satélite ERS-1. LUCCA et al. (1998) testaram, além do RWSEG, o algoritmo segmentador MUM (*Merge Using Moments*) em imagens JERS-1, sendo que este último produziu segmentos melhores em termos quantitativos.

2.4.5 Acuracidade Temática

As matrizes de erros ou tabelas de contingência são o meio mais comum de se expressar a acuracidade de uma classificação temática. Tais matrizes comparam, classe a classe, a relação entre os dados de referência conhecidos (verdade de campo) e os respectivos resultados de uma classificação automática (LILLESAND e KIEFER, 1994).

Normalmente utiliza-se um conjunto de pixels de referência, que são pontos na imagem classificada para os quais os dados reais são conhecidos (ERDAS, 1997).

CONGALTON (1991) recomenda que os pixels de referência sejam selecionados aleatoriamente na imagem, diminuindo, assim, a possibilidade de erros tendenciosos. Salienta, também, que são necessários mais de 250 pixels de referência para estimar a acuracidade média de uma classe com $\pm 5\%$ de erro. Os pontos de referência reais podem ser obtidos em amostragem de campo, através da tomada de suas coordenadas com GPS, amostrando todas as categorias consideradas (SILVEIRA, 1997). Se, no entanto, já existirem mapas contendo as classes de interesse, as duas imagens devem ser comparadas em nível de pixel – representados por um conjunto de amostras – para determinar exatamente a forma com que cada local na imagem de referência está representado na classificação (CAMPBELL, 1996).

A matriz de erros é uma matriz quadrada, de dimensão $c \times c$, onde c é o número de classes. Nas colunas está representado o número de pontos, segundo a verdade de campo, amostrado para cada classe. Nas linhas está o número de pontos encontrado para cada classe segundo a classificação automática. Dessa forma, a diagonal principal da matriz conterà o número de pixels classificados corretamente para cada categoria.

LILLESAND e KIEFER (1994) descrevem algumas medidas descritivas obtidas a partir da matriz de erros:

- a) acuracidade geral – é a razão entre o número total de pixels classificados corretamente e o número total de pixels de referência;
- b) acuracidade do produtor – é a razão entre o número de pixels classificados corretamente em cada categoria (na diagonal principal) e o número verdadeiro de pixels pertencentes àquela categoria (o total da coluna). É uma medida indicativa de quão bem os pixels pertencentes a uma categoria conhecida no terreno são classificados e reflete erros de omissão;
- c) acuracidade do usuário - é a razão entre o número de pixels classificados corretamente em cada categoria (na diagonal principal) e o número total de pixels classificados naquela categoria (o total da linha). Esta é uma medida que indica a probabilidade de que um pixel classificado em uma dada

categoria realmente represente aquela categoria no terreno e reflète erros de comissão.

Outro ponto a ser considerado na interpretação das acurácias temáticas é o coeficiente κ (kappa), que expressa a redução proporcional no erro gerado por um processo de classificação, comparado com o erro de uma classificação completamente aleatória (ERDAS, 1997). Esta estatística serve como um indicador da extensão com que os valores percentuais corretos de uma matriz de erros são devidos a concordâncias “reais” versus concordâncias “ao acaso” (LILLESAND e KIEFER, 1994). À medida que a concordância verdadeira (observada) se aproxima de 1 e a concordância ao acaso se aproxima de zero, κ se aproxima de 1, o que representa a situação ideal. Um valor de κ igual a 0.73, por exemplo, indica que uma classificação observada é 73% melhor do que outra classificação obtida aleatoriamente. A fórmula para o cálculo do coeficiente κ é dada por (VERBYLA, 1995):

$$\kappa = \frac{\text{Acurácia geral} - \text{Acurácia esperada}}{1 - \text{Acurácia esperada}}$$

A acurácia geral é calculada dividindo-se a soma de todos os pontos classificados corretamente pelo total de pontos amostrados. Para o cálculo da acurácia esperada é necessário, primeiramente, utilizar a matriz de erros para gerar uma matriz de produtos dos totais das linhas e colunas. O primeiro elemento (1,1) dessa matriz de produtos, por exemplo, seria obtido computando-se o produto do total da linha 1 pelo total da coluna 1 da matriz de erros. A soma de todos os elementos da diagonal dividida pela soma de todos os elementos da matriz de produtos dará origem à acurácia esperada. Uma fórmula equivalente, que produz exatamente os mesmos resultados, é apresentada em LILLESAND e KIEFER (1994):

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

em que:

- r = número de linhas na matriz de erros;
- x_{ii} = número de observações na linha i e coluna i (na diagonal principal);
- x_{i+} = número total de observações na linha i ;
- x_{+i} = número total de observações na coluna i ;
- N = número total de observações incluídas na matriz.

2.5 A UTILIZAÇÃO DE IMAGENS DE SATÉLITES NO MAPEAMENTO E CLASSIFICAÇÃO FLORESTAL

2.5.1 Imagens de Radar

Os radares de abertura sintética foram empregados com sucesso no mapeamento florestal, especificamente na separação de povoamentos jovens e maduros e, também, na detecção de danos causados por incêndios florestais (LICHTENEGGER, 1994). No entanto, no caso de florestas em regiões montanhosas com encostas íngremes, há a necessidade de se aplicar correções geométricas rigorosas, usando um modelo digital do terreno e órbitas descendentes e ascendentes para que efeitos como sombras de radar e inversão do relevo possam ser minimizados.

KATTENBORN et al. (1994) afirmam que, quando comparados aos sensores ópticos multiespectrais, as aplicações florestais para imagens SAR aparentam ser limitadas. Contudo, a cobertura dos sistemas radares orbitais permite o preenchimento de eventuais lacunas da cobertura óptica devida a mau tempo, nuvens, etc.

Um dos usos potencialmente importantes das imagens SAR é o mapeamento da cobertura vegetal em florestas tropicais, que estão freqüentemente cobertas por nuvens e, portanto, inacessíveis a sensoriamento óptico (QUEGAN, 1997).

A Floresta Nacional do Tapajós, no Estado do Pará, tem sido objeto dos mais diversos estudos sobre aplicações de imagens SAR envolvendo os seguintes temas:

- a) comparação de algoritmos classificadores (SANT'ANNA et al., 1997);
- b) relações entre biomassa e coeficiente de retroespalhamento (CURRAN e KUPLICH, 1999; LUCKMAN et al., 1999);
- c) utilização de imagens-textura para a discriminação de floresta primária (DUTRA et al., 1999);
- d) mapeamento de tipos florestais e detecção de alterações na cobertura do solo (SHIMABUKURO et al., 1998);
- e) estimativa da altura média das árvores na borda de clareiras utilizando pares estereoscópicos de imagens RADARSAT *fine mode* (TOUTIN e AMARAL, 1998).

Ainda na região amazônica, porém no Estado do Acre, SCALES et al. (1997) avaliaram o desempenho de imagens ERS-1 SAR para o mapeamento de áreas com e sem cobertura florestal, além do monitoramento da floresta tropical e diferenciação de intensidade de uso do solo. Embora a separação de áreas com floresta e sem floresta tenha sido bem sucedida na maioria das áreas estudadas, algumas regiões desflorestadas foram classificadas erroneamente devido a dois fatores preponderantes:

- a) alterações no relevo e, por conseguinte, na iluminação do radar;
- b) grandes quantidades de vegetação arbustiva e de grupos de árvores remanescentes (p.e., palmeiras), que aumentaram o sinal de retorno e as variâncias na textura.

Investigando a dinâmica do desflorestamento em Rondônia, SCHMIDT et al. (1997) concluíram que há grandes limitações na discriminação de classes como floresta primária e áreas de regeneração com mais de quatro anos de idade quando se

utiliza sensores radares que operam na banda C, com polarização VV (ERS-1, p.e.). Isso se deve à sua pouca profundidade de penetração no substrato.

QUEGAN (1997) afirma que bandas de ondas mais longas são melhores para o sensoriamento de florestas. Uma vez que o padrão de retorno de uma superfície é função da rugosidade – medida em relação ao comprimento de onda – imagens de ondas mais longas são mais adequadas para distinguir campos úmidos de floresta primária e sucessional e, assim, melhores para mapear o desflorestamento e regeneração nos trópicos (SALAS et al., 1999).

A utilização de técnicas de análise multitemporais, combinando-se três imagens adquiridas em épocas diferentes pode conduzir a melhores resultados na separação de florestas, pastos e vegetação secundária, uma vez que essa distinção depende do conteúdo de umidade e, portanto, da sazonalidade.

DOBSON et al. (1999) empregaram imagens JERS-1 SAR e ERS-1 SAR para estabelecer uma classificação de uso do solo com base em atributos estruturais da superfície e da cobertura vegetal. Concluíram que a combinação de dados SAR das bandas L e C permite extrair mais informações das assinaturas combinadas do retorno de radar do que quando se utiliza apenas um dos sensores.

Da mesma forma COSTA et al. (1998a, 1998b) obtiveram melhores resultados na classificação de habitats na Planície Amazônica quando utilizaram imagens combinadas dos sensores JERS-1 SAR e RADARSAT.

ARMAND et al. (1999) demonstraram que a utilização de imagens JERS-1 SAR de diferentes estações do ano oferece novas possibilidades na separação de florestas de coníferas e decíduas, com base no sinal de retorno de radar. No Hemisfério Norte, na primavera (portanto início do período vegetativo) o nível de retorno do sinal de radar – expresso em decibéis (dB) – para coníferas e decíduas se equivale (-11 dB e -10 dB, respectivamente). No entanto, no outono, o sinal das florestas de coníferas é igual a -6,6 dB, enquanto que o das decíduas é de -9 dB, o que permite diferenciá-las.

JESUS (1998) empregou elementos como textura, padrão e forma na interpretação visual de imagens RADARSAT *fine mode* para gerar mapas temáticos de uma empresa florestal. Foi possível delimitar classes de cobertura e uso do solo, tais

como áreas alagadas, cerrados, pastagens, mata de galeria, floresta nativa, áreas urbanas e reflorestamento (*Pinus spp*, *Eucalyptus spp*, *Acacia spp*).

Vários mosaicos de imagens JERS-1 SAR foram criados para regiões da África Equatorial, Norte da Austrália, Nova Guiné, florestas tropicais na África Central e na Amazônia Brasileira (EORC, 1999). A principal vantagem dos mosaicos é permitir uma visão geral dos diferentes tipos de floresta, de modo a facilitar seu mapeamento, bem como o de reflorestamentos, além de monitorar taxas de desmatamento e investigar recursos naturais baseando-se em topografia.

BARRETT e CURTIS (1999) relatam a utilização de imagens de radar no mapeamento de áreas florestais da Nigéria, onde as condições atmosféricas apontam o radar como o sensor mais prático em muitas regiões. Os produtos gerados pelo levantamento foram mosaicos em escala 1:250.000, compatível com os mapas disponíveis. Foi possível executar um inventário dos tipos florestais, das unidades primárias de estratificação e das reservas existentes.

As diferenças texturais em composições coloridas de imagens JERS-1 SAR foram empregadas para diferenciar florestas naturais e plantadas na África Central (EORC, 1999). SANO et al. (1999) investigaram o potencial de imagens JERS-1 SAR adquiridas durante a estação chuvosa para discriminar os principais tipos de vegetação no cerrado brasileiro.

WU (1987) aplicou técnicas de regressão linear para estimar a biomassa, altura média e idade de plantações de *Pinus spp*, usando imagens de radar (SIR-A) na banda L e com polarização VV e VH. Os resultados indicaram que dados de multipolarização são altamente correlacionados com a biomassa de povoamentos desse gênero. RANSON e SUN (1994) ressaltam que as ondas mais longas (bandas L e P) e polarização cruzada (HV) possuem uma maior correlação com a biomassa florestal pelo fato de que a difusão múltipla – que contribui para o retorno da polarização cruzada – acontece, principalmente, nas partes mais baixas do dossel, isto é, em galhos grandes e troncos.

GUERRA et al. (2000) testaram modelos não-lineares para estimar volume de madeira (m^3 /ha) e densidade de árvores (fustes/ha) em povoamentos homogêneos de

Pinus caribaea, não-manejados, em terreno plano. Os dados de campo dos parâmetros florestais foram utilizados para calibrar e validar modelos de regressão obtidos de imagens JERS-1 SAR. Considerando volumes máximos de 250 m³ /ha, a avaliação global dos modelos empíricos, tanto para plantações jovens como adultas foi de 26 m³/ha. Nos modelos de regressão testados foi empregado o coeficiente de retroespalhamento (σ^0).

A grande amplitude de sinais de retorno de radar e a sua sobreposição para folhosas e outros tipos de florestas torna difícil mapear a tipologia florestal (p.e., coníferas, folhosas, povoamentos mistos, áreas de corte raso) somente utilizando dados de radar. AHERN et al (1993b) consideram que, para que se possa obter informações úteis a partir de sistemas radares orbitais em nível de espécie, os povoamentos precisam ser grandes e homogêneos e o efeito da topografia deve ser levado em consideração. Já a capacidade de mapeamento de áreas de corte raso é afetada pelas seguintes variáveis:

- a) frequência de radar (com o contraste entre áreas desflorestadas/florestadas aumentando da banda X para a banda C para a banda L);
- b) tipos florestais sendo considerados;
- c) relevo, estação do ano e ângulo de incidência.

A separação entre diversas espécies de coníferas utilizando sensores de microondas na banda C foi investigada por CHURCHIL e KEECH (1984), LECKIE (1990) e AHERN et al. (1993a). A menor amplitude dos sinais de retorno considerando-se exclusivamente grupos de folhosas, dificulta a separabilidade entre essas espécies quando se utiliza a banda C (AHERN et al., 1993b).

ROSOT et al. (2001), ao avaliarem a potencialidade de imagens JERS1-SAR para fins de atualização cartográfica em áreas de reflorestamentos no Estado do Paraná, recomendaram a utilização de produtos híbridos, integrando imagens ópticas e de radar, mais apropriados à diferenciação de talhões de diferentes espécies e tratos silviculturais.

2.5.2 Imagens Ópticas

Os sensores ópticos têm sido largamente empregados nas últimas três décadas, produzindo imagens sinópticas repetitivas, em escalas pequenas, adequadas à medição de parâmetros biofísicos e ao monitoramento de alterações em nível de meio-ambiente (PITT et al., 1997). A partir de 1999 iniciou-se uma nova era de satélites comerciais de observação da terra e novas aplicações para o manejo da vegetação certamente surgirão com a geração de imagens cuja resolução espacial varia de 1 a 3 m no modo pancromático e de 4 a 15 m no modo multiespectral (FRITZ, 1996).

COLEMAN et al. (1989) utilizaram dados LANDSAT TM num estudo para diferenciar povoamentos naturais e plantados de *Pinus spp* com diferentes densidades de copa, atingindo elevados níveis de acurácia temática. As imagens LANDSAT TM também foram utilizadas em outros estudos para avaliar sua capacidade de diferenciar espécies florestais e classes de idade dos povoamentos, servindo como subsídio às operações de manejo florestal (COLEMAN et al., 1990).

DUCATI et al. (2000) classificaram imagens LANDSAT TM, empregando o método de máxima verossimilhança para identificar e separar reflorestamentos de *Pinus elliottii*, de *Eucalyptus spp*, *Acacia sp*, *Araucaria angustifolia*, solo exposto e área urbana. A soma das áreas das classes obtidas diferiu em apenas 0,6% com relação às áreas dos municípios, fornecidas por órgãos oficiais. A precisão das áreas com florestas exóticas foi confirmada através da comparação com cartas em escala 1:25000, fornecidas por empresas madeireiras.

ANTUNES (1996) utilizou imagens LANDSAT-5 TM para identificar diferentes classes de vegetação da APA de Guaraqueçaba – PR.

LOCH (2000) comparou diferentes métodos de análise temporal de imagens de satélite em áreas degradadas pela mineração no Estado de Santa Catarina. As áreas degradadas e reflorestadas com *Eucalyptus spp* foram discriminadas nas imagens LANDSAT-5 TM em duas classes: *Eucalyptus spp* jovem e *Eucalyptus spp* adulto.

KAZMIERCZAK (1992) utilizou imagens LANDSAT-5 TM para avaliar a relação entre os valores digitais de imagens orbitais TM e as variáveis dendrométricas

de florestas homogêneas. Neste estudo – efetuado na Floresta Nacional de Passo Fundo, RS – em povoamentos plantados de *Araucaria angustifolia* e *Pinus spp*, a banda 5 apresentou maior potencial para distinguir pequenas variações dentro de uma mesma espécie.

SILVEIRA (1997) utilizou imagens LANDSAT-5 TM para detectar alterações na cobertura vegetal no litoral do Paraná. Identificou e mapeou áreas de reflorestamentos de *Pinus spp* e outros tipos florestais com a composição colorida 4,5,7 (RGB) através do software IDRISI.

SOUSA (1997) trabalhou com imagens LANDSAT-5 TM para avaliar alterações no volume de madeira de reflorestamentos de *Pinus spp* submetidos à prática de desbastes. Os resultados indicaram que as imagens-índice e as imagens-proporção não foram sensíveis às variações em volume decorrentes da aplicação dos desbastes.

BUTERA (1986), estudando uma Floresta Nacional no Colorado (EUA), analisou a correlação do grau de cobertura em função da reflectância a partir de dados do TMS (*Thematic Mapper Simulator*), cujas bandas são equivalentes às do sensor TM. Concluiu que as bandas 1, 5 e 7 são as que fornecem maiores informações sobre o grau de cobertura.

KLEMAN (1987) estudou a variação de reflectância em *Picea sp* e *Pinus sp*, concluindo que em áreas de *Picea sp* a reflectância era maior do que em áreas de *Pinus sp*, devido à sua estrutura vertical mais pronunciada e maior biomassa.

Utilizando imagens LANDSAT-5, KURTZ e LIGIER (2000) analisaram os valores de reflectância de plantações florestais correspondentes às bandas 3, 4 e 5. Os picos de reflectância foram obtidos na banda do infravermelho próximo, sendo que as áreas com *Eucalyptus grandis* apresentaram valores de reflectância sempre mais altos, em comparação com *Pinus elliottii* e *Pinus taeda*.

SANTOS (1988) relata alguns estudos em que dados de sensoriamento remoto das bandas do infravermelho próximo e vermelho são relacionados com elementos da vegetação, como a área basal, percentagem de cobertura e índice de área foliar (IAF).

DANSON (1987), avaliando dados do sensor HRV-SPOT, observou fortes correlações negativas entre a resposta da banda 3 (infravermelho próximo) e variáveis florestais (DAP, altura total, idade), sugerindo que estas relações não são função da quantidade de vegetação, mas devidas à variação na quantidade de sombra.

Um estudo das correlações entre dados digitais TM e variáveis de florestas plantadas (SHIMABUKURO et al., 1989) demonstrou que a razão das bandas TM4/TM3 é a que apresenta maior correlação com a densidade de povoamentos de *Pinus spp* ($r=0,606$), enquanto que a banda TM4 possui uma correlação igual a $-0,475$ com a idade de povoamentos de *Eucalyptus spp*.

ROSOT et al.(2000) analisaram imagens transformadas pela técnica IHS quanto à sua eficiência no reconhecimento de feições urbanas e mapeamento da vegetação na região do manguezal de Itacorubi, na Ilha de Santa Catarina. A combinação dos sensores LANDSAT TM e SPOT HRV permitiu reunir a resolução espacial necessária à discriminação dos alvos urbanos associada à informação espectral indispensável à identificação dos diversos tipos de vegetação existentes na área.

Ao investigar o comportamento espectral de algumas coníferas utilizadas em reflorestamentos na Floresta Nacional de Irati – PR, empregando dados do sensor LANDSAT-5 TM, OLIVEIRA (2000) concluiu que as respostas espectrais para plantações de *Araucaria angustifolia* e *Pinus taeda* são similares. Porém, quando considerada a variação dentro do gênero *Pinus*, o *Pinus elliottii* apresentou valores mais brilhantes do que o *Pinus taeda*. As diferenças na textura foram identificadas na região do infravermelho médio.

2.5.3 Imagens Combinadas

SANTOS e LACRUZ (1998) consideram que dados ópticos (LANDSAT TM) e de microondas (JERS-1, RADARSAT) são as fontes de informação fundamentais para a análise quantitativa de dados de biomassa devido à forte dinâmica das alterações de uso do solo.

AHERN et al. (1993b) afirmam que, em aplicações de imagens SAR envolvendo o mapeamento de áreas de corte raso e de áreas queimadas, é aconselhável a sua integração com sensores ópticos, tais como o LANDSAT TM ou o SPOT. Na porção oeste da Amazônia Brasileira, imagens combinadas RADARSAT e LANDSAT TM foram empregadas para gerar um produto híbrido, onde o relevo foi enfatizado pelo radar através do brilho da imagem e a informação sobre os tipos de vegetação originou-se, principalmente, do *Thematic Mapper*, aparecendo em cores diferentes.

MOREAU e BOURREL (1998) empregaram a transformação IHS para combinar dados RADARSAT SAR, ERS-2 SAR e LANDSAT TM, objetivando o mapeamento da vegetação de áreas de várzea da Amazônia Boliviana. Os melhores resultados foram obtidos quando da integração RADARSAT – TM, sendo possível distinguir floresta higrófila densa, matas de galeria e savanas, substituindo-se a imagem SAR no lugar da componente intensidade do espaço IHS.

Quanto à discriminação de diferentes tipologias florestais, LECKIE (1990) demonstra que as imagens de radar e as ópticas na região do visível/infravermelho são complementares entre si. As imagens ópticas apresentam boa discriminação para grandes grupos tais como florestas de coníferas, floresta de folhosas, plantios mistos de várias espécies, etc, enquanto que o radar parece ser mais efetivo na distinção de espécies de coníferas.

DOBSON et al. (1999) efetuaram classificações híbridas em imagens compostas pelos sensores SPOT XS, JERS-1 e ERS-1 em sete ecorregiões das Américas. Os dados ópticos foram superiores na distinção entre as classes água/não-água e decíduas/coníferas, mas não apresentaram bons resultados na discriminação de diferentes tipos de coníferas e na separação de várzeas e campos. Devido à sua capacidade de penetração na folhagem, os dados SAR demonstraram superioridade nas discriminações relacionadas a variações entre classes de biomassa aérea e arquitetura dos troncos. Os melhores resultados foram obtidos na fusão da banda 3 do SPOT XS (canal infravermelho) com ambas as bandas SAR (L e C).

SOARES et al. (1997) integraram dados multiespectrais do sensor LANDSAT TM e dados SAR do sensor JERS-1 para gerar um produto híbrido que servisse de

base à elaboração de uma carta-imagem da Floresta Nacional do Tapajós, no Estado do Pará. A cena LANDSAT continha áreas de desinformação provocada por nuvens e sombras que, após a fusão de dados, foi reposta pela textura da imagem SAR. As técnicas de fusão utilizadas envolveram a transformação IHS aplicada sobre uma composição colorida de componentes principais oriundas das bandas originais 1, 2, 3, 4, 5 e 7 do sensor TM. A imagem JERS-1 SAR substituiu a componente intensidade.

GOMEZ (1997) também empregou a transformação IHS em dados ERS-1 SAR e LANDSAT-4 TM para uma avaliação qualitativa na interpretação visual do uso da terra e cobertura vegetal na região pré-andina e planície *llanera* na Venezuela. A melhor combinação foi aquela em que a componente saturação foi substituída pela imagem SAR, atribuída, posteriormente, ao canal azul do espaço RGB, com as bandas 5 e 4 nos canais vermelho e verde, respectivamente.

DUPAS (2000) empregou fusão de imagens LANDSAT TM, ERS-1 e JERS-1 para a classificação de cobertura de solo numa área de domínio da Mata Atlântica. Foram testadas duas técnicas de fusão de dados – transformação IHS e transformação de Brovey, descrita em POHL (1996) – sendo a primeira considerada mais adequada. A combinação de dados ópticos com a banda L de radar conduziu sempre a acurácias temáticas mais elevadas quando comparada à fusão de imagens ópticas com a banda C. Foi possível classificar floresta nativa e plantações de eucalipto com acurácias de 92,3% e 69,2%, respectivamente.

A fusão de dados ópticos e de microondas também pode ser efetuada por combinação simples de bandas, sem empregar transformação no espaço de cores (MANORE et al., 1997). Procurando avaliar as potencialidades do uso combinado de imagens RADARSAT e LANDSAT-5 TM no mapeamento geo-ambiental, SILVA JR (1999) concluiu que as composições que usaram a banda C de radar no canal vermelho mostraram-se mais adequadas para interpretação visual, provocando uma maior variação tonal das classes. Entre as melhores composições destacaram-se a C, 5, 3 (RGB), significativa para uma interpretação geral da área e 5, 4, C (RGB), onde as áreas de reflorestamento de eucalipto e várzea mostraram-se bem definidas.

NEZRIT e DEMARGNE (2000) usaram imagens SPOT pancromáticas e multiespectrais em combinação com imagens RADARSAT SAR, adquiridas com diferentes ângulos de visada, além de um par interferométrico de imagens ERS SAR, para estabelecer um inventário florestal e avaliar as reservas de madeira na Malásia. Os dados de radar complementaram a imagem SPOT em zonas onde a cobertura de nuvens tornava inviável o recobrimento óptico. Sua integração aos dados SPOT gerou informações temáticas que auxiliaram na discriminação de diferentes tipos florestais.

3 MATERIAL E MÉTODOS

3.1 DESCRIÇÃO DA ÁREA DE ESTUDO

A área de estudo (Fig. 15) está localizada na Fazenda Mocambo, de propriedade da Pisa Florestal S.A., situada no Município de Sengés – PR, distante 280 km da cidade de Curitiba. Da área total da fazenda, que consiste em 26.800 ha, foram selecionados cerca de 5.000 ha para o desenvolvimento desta pesquisa, compreendidos entre as coordenadas 24°06'45" e 24°11'02" de latitude Sul e 49°19'53" e 49°25'12" de longitude oeste.

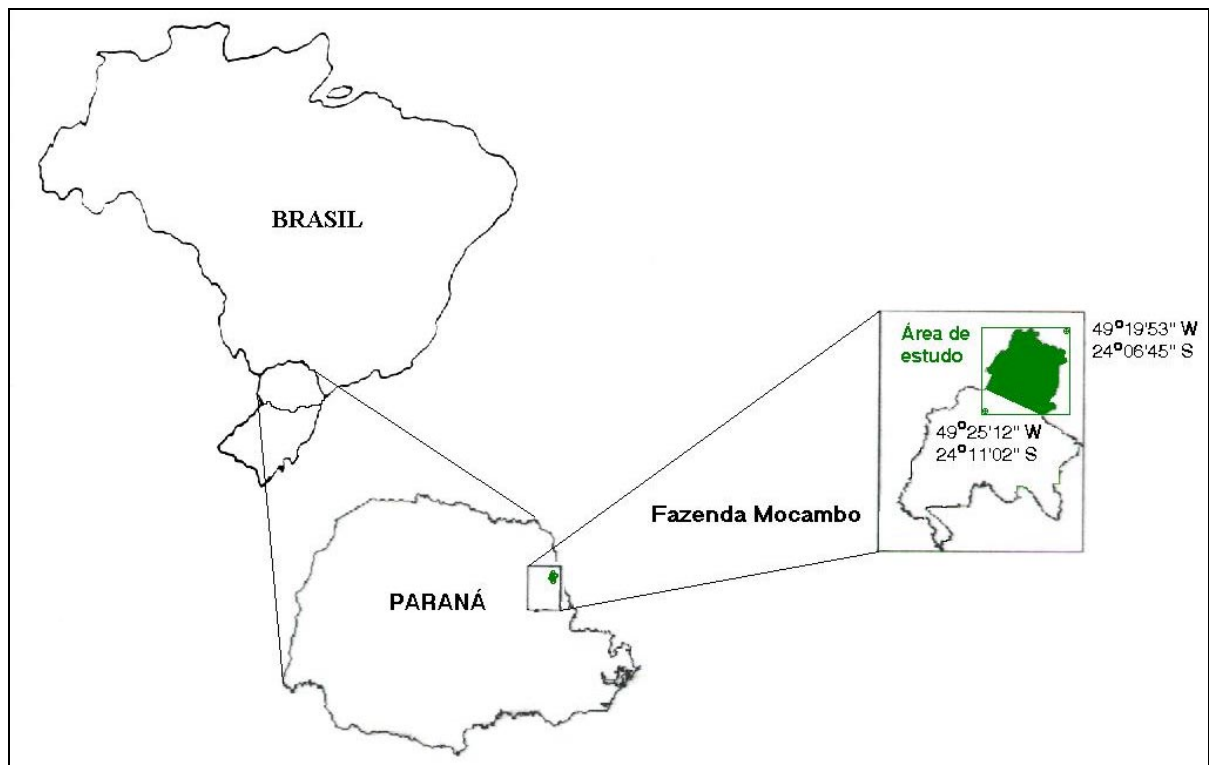


FIGURA 15 – LOCALIZAÇÃO DA ÁREA DE ESTUDO NO BRASIL E NO ESTADO DO PARANÁ

3.1.1 Clima

O clima da região é predominantemente do tipo *Cfb*, segundo a classificação de Koeppen, que indica clima mesotérmico, subtropical úmido, sem estação seca e

com verões quentes (ATLAS, 1990).

Segundo informações constantes do cadastro da empresa, a temperatura média anual da área de estudo é de 20,3°C, com média mínima de -1,3°C e média máxima 34°C. A precipitação média anual varia de 1200 mm a 2000 mm. Entretanto, após a análise dos dados dos últimos 20 anos, obtidos de uma estação localizada na sede da Fazenda Capivari, município de Sengés, observou-se que a temperatura média do mês mais quente é superior a 22° C, caracterizando o clima como *Cfa*. Isto ocorre porque o município de Sengés situa-se no limite de ocorrência dos climas *Cfa* e *Cfb* (ATLAS, 1990). A predominância da direção dos ventos é dos quadrantes sulinos, que segundo MAACK (1981), são os ventos que desfazem as chuvas e os ventos que sopram dos quadrantes norte são os causadores de chuva.

3.1.2 Geologia e Geomorfologia

A região é caracterizada por relevo suavemente ondulado e a geologia faz parte da formação Guatá ou Itararé, com rochas de argilito, folhelhos pirobetuminosos, siltitos, calcáreos e conglomerados (NADOLNY, 1995). A altitude média é de 800 m, variando de 600 m a 1030 m.

3.1.3 Vegetação

A região fitogeográfica enquadra-se, segundo o sistema fitofisionômico-ecológico proposto por IBGE (1990), como Savana Arbórea Aberta. Esta tipologia concentra-se principalmente nas proximidades de Itararé (SP) e Jaguariaíva e Tibagi no Paraná. São formações típicas de Savana (cerrado) constituindo disjunções ou áreas de contato com as regiões das Florestas Ombrófila Mista e Estacional Semidecidual. Apresenta, normalmente, um estrato arbóreo-arbustivo esparso, perenifoliado e com características de escleromorfia oligotrófica, sob o qual se desenvolve um estrato descontínuo de plantas hemicriptófitas, caméfitas e geófitas. No primeiro estrato encontram-se freqüentemente o barbatimão (*Stryphnodendrum barbadetiman*), o

angico (*Anadenanthera peregrina*), o barbatimão-da-folha-miúda (*Dimofandra mollis*), o mercúrio-do-campo (*Erythroxylum suberosum*), o pau-d'óleo (*Copaifera longsdorffii*), o cinzeiro (*Vochysia tucanorum*) e o saco-de-boi (*Kielmeyera coriacea*), além de outras espécies. O estrato inferior compõe-se principalmente de *Andropogon spp*, *Aristida spp*, *Brisa spp*, *Poidium spp*, *Axonopus spp*, *Tristachya spp* e representantes das liliáceas, amarilidáceas, iridáceas e compostas (IBGE, 1990).

MAACK (1981) descreve estas formações como campo cerrado ou estepe arbustiva, desenvolvendo-se lentamente a partir das áreas livres de campos limpos, nas altitudes de 730 a 1100 metros acima do nível do mar, sendo que as cidades de Jaguariaíva e Sengés localizam-se em meio destes campos cerrados.

3.1.4 Reflorestamentos

A Fazenda Mocambo é composta por áreas de reflorestamentos, com talhões de diferentes tamanhos, englobando *Pinus elliottii*, *Pinus taeda* e diferentes espécies de *Eucalyptus*. Tais reflorestamentos são encontrados em várias idades e diferentes densidades de plantio, com espaçamentos variando de 2 m x 2 m a 3m x 2 m. Os regimes de manejo variam conforme o gênero e a utilização final da madeira. Os povoamentos de *Eucalyptus spp* destinam-se à geração de energia (lenha) e também para a produção de postes e mourões de cerca. Os povoamentos de *Pinus spp* são empregados para a produção de madeira serrada, laminação, celulose e papel.

Para a produção de energia os povoamentos de *Eucalyptus spp* são manejados em regime de talhadia simples; para a produção de postes o regime de manejo empregado é o de talhadia composta, sendo que as idades variam em função das dimensões do produto desejado. Geralmente são efetuadas até três talhadias, dependendo da espécie e da classe de sítio dos talhões.

Nos povoamentos de *Pinus spp* o principal regime de manejo consiste na realização de cerca de três desbastes, com intervalos de três a quatro anos, iniciando-se a partir do 7º.- 8º. ano, dependendo do espaçamento inicial e da classe de sítio do talhão. Normalmente o corte final (corte raso) é efetuado em torno de 20 anos, sendo

condicionado à necessidade de matéria-prima e/ou às dimensões do produto final. As árvores do corte final destinam-se à laminação e à produção de madeira serrada. Os produtos do primeiro desbaste são empregados, quase que exclusivamente, para a produção de celulose. No segundo e terceiro desbastes, parte da madeira é destinada à produção de madeira serrada e o restante, para papel e celulose. Após o corte final a área é preparada para um novo plantio através de mudas embaladas.

3.2 MATERIAL

3.2.1 Imagens de Satélites

Foram empregadas imagens de sensores ópticos (LANDSAT 5 TM) e de microondas (JERS-1).

3.2.1.1 Imagem JERS

Foi empregada uma imagem do sensor de microondas (JERS-1/SAR) em CD no formato CEOS-BSQ, correspondente à órbita 387, ponto 341, de 18/12/1995. A imagem foi doada pela Agência Nacional de Desenvolvimento Espacial do Japão (NASDA) para o projeto n°. J-2RI-004, intitulado “*Combining orbital SAR and optical data for mapping and classification of Pine and Eucalyptus plantations in southern Brazil*”, conforme convênio efetuado entre esta instituição e o Departamento de Ciências Florestais – UFPR.

3.2.1.2 Imagens LANDSAT-5 TM

Foi adquirida uma imagem LANDSAT 5 do sensor *Thematic Mapper* (TM), com seis bandas espectrais (TM1 a TM5 e TM7), órbita 221, ponto 77 segundo o WRS (*World Reference System*). Para que fosse possível efetuar a fusão de dados, foi

selecionada a data de 03/12/1995, que mais se aproximava da data de aquisição da imagem JERS (18/12/1995).

O produto foi solicitado em CD, no formato TIFF com nível de processamento 5, em que são efetuadas correções geométricas básicas na imagem, com reamostragem por vizinho mais próximo.

3.2.2 Dados Auxiliares para Controle de Campo

Foi utilizado o mapa do IBGE - Departamento de Cartografia da cidade de Itararé, folha SG-22-X-B-I-1 na escala de 1:50.000, elaborado a partir de fotografias aéreas de 1965, com apoio suplementar e reambulação executados em 1974.

As fotos aéreas resultantes do levantamento aerofotogramétrico realizado para a COPEL em 1997, escala 1:50.000, doadas pela empresa Engefoto – Engenharia e Aerolevantamentos S.A., foram utilizadas para verificação da tipologia, da rede de estradas e da divisão dos talhões. Também foram adquiridas fotos aéreas do levantamento aerofotogramétrico realizado para a Pisa Florestal S.A. em 1989, escala 1:25.000, num vôo efetuado pela empresa Aerosul S.A. – Levantamentos Aeroespaciais e Consultoria. Por ocasião do aerolevanteamento foram gerados dois arquivos vetoriais em meio digital, georreferenciados, um deles contendo a altimetria da fazenda Mocambo e, o outro, a divisão dos talhões e estradas, empregados nesta pesquisa nas etapas de geração de modelo numérico do terreno e ortorretificação.

O cadastro florestal, estruturado em 1990 e composto pelo banco de dados do manejo florestal, é atualizado sempre que houver qualquer alteração nas unidades mínimas de manejo (talhões). Foram utilizados os dados referentes aos povoamentos, correspondentes à época em que foram tomadas as imagens JERS. Os mapas temáticos e topográficos da empresa foram considerados como a “verdade de campo” nos procedimentos de classificação e mapeamento.

3.2.3 Equipamentos e Programas

3.2.3.1 Equipamentos

Foi utilizada uma estação SUN Solaris, em ambiente UNIX e também um computador PC Pentium 1000, em ambiente Windows, com 256 MB de memória RAM e HD de 30 GB.

3.2.3.2 Programas

Para o processamento dos dados foram empregados os seguintes *software*:

- a) ENVI, versão 3.2 (*The Environment for Visualizing Images*)
- b) SPRING, versão 3.5 (Sistema de Processamento de Informações Georreferenciadas)
- c) PCI Geomatics

A base do processamento de dados foi o *software* SPRING. O *software* ENVI do Laboratório de Sensoriamento Remoto do Departamento de Ciências Florestais da Universidade Federal do Paraná e o *software* PCI do Laboratório de Tratamento de Imagens Digitais – LTID/INPE foram utilizados complementarmente para a execução de tarefas específicas.

3.3 MÉTODO

O desempenho de técnicas de processamento digital de imagens na classificação e elaboração de mapas das áreas de reflorestamentos foi avaliado em abordagens distintas para os sensores de microondas (JERS1-SAR) e ópticos (LANDSAT-5 TM), isoladamente e para os produtos de sua fusão.

3.3.1 Imagem JERS

3.3.1.1 Pré-processamento

A partir da imagem JERS original, composta por 6000 colunas e 6400 linhas, foi efetuado um recorte contendo a área de estudo.

Para produzir imagens de radar que possam ser interpretadas, é necessário efetuar a transformação matemática dos dados brutos adquiridos pelo sensor, incorporando-se correções radiométricas e geométricas. As imagens utilizadas nesta pesquisa foram pré-processadas pela Agência Nacional de Desenvolvimento Espacial do Japão (NASDA) com um nível de correção 2.1, que equivale ao georreferenciamento padrão da imagem reamostrada para a projeção UTM.

Na Tabela 6 encontram-se listadas as características das cenas disponibilizadas pelo Centro de Pesquisas de Observações da Terra (EORC)³, correspondentes ao nível de processamento 2.1 do sensor JERS-1 SAR.

As imagens de radar pré-processadas apresentam-se num formato original de 16 bits. A conversão de inteiro para *byte* (de 16 para 8 bits) não foi efetuada como uma etapa do pré-processamento, mas, sim, durante o processo de ortorretificação, descrito nos capítulos seguintes.

TABELA 6 – CARACTERÍSTICAS DO PRODUTO JERS-1 NÍVEL 2.1

CARACTERÍSTICAS	
Georreferenciamento	Sim
Correção do padrão de antena	Sim
Correção para o ângulo de incidência local	Sim (baseado no elipsóide)
Correção para as perdas no alcance (<i>range</i>)	Sim
Número de visadas (<i>looks</i>)	4
Geometria SAR	Corrigida para distância no terreno
Tamanho do pixel no <i>range</i> e no azimute	12.5 m
Resolução espacial	18 m
Largura da cena no <i>range</i>	75 km
Largura da cena no azimute	80 km
Número de pixels no <i>range</i>	6000
Número de pixels no azimute	6400

3.3.1.1.1 Correções geométricas

Previamente à execução do procedimento de ortorretificação, optou-se por efetuar a correção geométrica da imagem JERS utilizando os métodos usuais baseados em transformações afins. O procedimento de correção geométrica ou retificação envolveu duas operações distintas: a estimativa dos coeficientes e posterior aplicação da função de mapeamento para o novo sistema de referência e a reamostragem, que atribuiu novos valores de cinza aos pixels da imagem geometricamente corrigida.

O número de pontos de controle necessários depende, primeiramente, do terreno, do tamanho da área e da disponibilidade de bons pontos, que sejam facilmente identificáveis no terreno e na imagem (VERBYLA, 1994). O número mínimo de pontos, no entanto, depende da ordem do modelo polinomial empregado na transformação e é expresso pela equação (SPRING, 1998a; ERDAS, 1997):

$$N = \frac{(t^2 + 3t + 2)}{2}$$

em que:

N = número mínimo de pontos

t = ordem da transformação

Por se tratar de uma imagem de radar foi empregada uma transformação linear de terceira ordem (ERDAS, 1997), que exige um número mínimo de 10 pontos de controle no terreno. Este critério, contudo, é meramente matemático, pois, estatisticamente, um maior número observações no processo de regressão conduz a resultados mais confiáveis.

A precisão da função de mapeamento é determinada por um erro ou desvio, denominado **erro da raiz quadrada média** (RMS), que é a distância entre as coordenadas reais e as transformadas para um mesmo ponto (SILVEIRA, 1997), sendo expresso pela equação (ERDAS, 1997):

$$\text{RMS} = \sqrt{(x_r - x_i)^2 + (y_r - y_i)^2}$$

onde:

x_i e y_i são coordenadas reais

x_r e y_r são coordenadas transformadas

O RMS total descreve o erro de posicionamento característico de todos os pontos de controle em relação à equação, descrevendo a probabilidade com a qual uma posição mapeada poderá variar da sua localização verdadeira. De acordo com os padrões de acurácia dos mapas dos Estados Unidos, o RMS para imagens deve ser menor que 0,5 da resolução da imagem de entrada (EASTMAN, 1998). Para as imagens JERS, cuja resolução espacial é de 18 m, o RMS não deve, portanto, exceder a 9 m.

O RMS por ponto de controle permite que pontos “ruins”, ou seja, com valores altos para o RMS, sejam retirados do conjunto de pontos utilizados no cálculo da equação de mapeamento. Então, novos coeficientes são estimados e novos valores são obtidos para o RMS total e por ponto. O procedimento deve ser repetido até que seja atingido um nível de precisão aceitável.

O método de reamostragem empregado foi o da interpolação bilinear, que leva em consideração a média dos DN's originais dos quatro pixels mais próximos para atribuir o novo nível de cinza a cada pixel da imagem geometricamente corrigida. Este método é o mais adequado para imagens de satélite (EASTMAN, 1998), além de possuir melhor precisão geométrica e produzir imagens com menos discontinuidades (ERDAS, 1997).

Para a correção geométrica empregou-se o método “imagem-mapa”, ou seja, foram identificados 12 pontos de controle (**GCPs** – *Ground Control Points*) na imagem e no mapa planimétrico em meio digital, com escala original igual a 1:10.000, elaborado a partir de aerolevanteamento efetuado em 1989, oriundo de restituição aerofotogramétrica.

Com a finalidade de melhorar a visualização da imagem e, assim, facilitar a localização dos pontos de controle, foram aplicadas técnicas para redução do *speckle*, testando-se os filtros adaptativos de Lee, Lee-Sigma, Frost e Kuan, com diferentes tamanhos de janelas, além de filtros de média e mediana.

3.3.1.1.2 Ortorretificação

Considerando que a geometria das imagens de radar freqüentemente causa distorções que permanecem mesmo após terem sido efetuadas correções geométricas, optou-se por realizar a ortorretificação da imagem JERS1-SAR. Este procedimento objetivou, principalmente, a correção das distorções causadas pelo relevo, uma vez que a área de estudo não é totalmente plana.

O modelo de correção geométrica para ortorretificar imagens utilizando um modelo digital de elevação foi originalmente desenvolvido para o SPOT-HRV e testado com dados LANDSAT-TM, MOS-MESSR, SEASAT-SAR e com dados SAR aerotransportados. Este mesmo modelo foi incorporado ao *software* PCI através dos módulos SMODEL e SRORTHO que integram o componente *OrthoEngine Sensor Rectification*, responsável pela geração de orto-imagens a partir de dados ERS, JERS e RADARSAT (ANDRADE, 2000).

O algoritmo de ortorretificação implementado no *software* PCI envolve, portanto, duas etapas distintas. A primeira diz respeito à construção do modelo do satélite, executada através do módulo SMODEL (*Satellite MODEL*). Para tanto foram necessários:

- a. a imagem original SAR, contendo a cena inteira;
- b. os dados de efemérides do satélite;
- c. pontos de controle (GCPs) definidos pelo usuário.

Empregou-se aqui a imagem JERS1-SAR original, portanto não submetida previamente a nenhuma correção radiométrica, por ser esta uma exigência do modelo. Assim, não foram aplicados filtros para a redução do *speckle*. No entanto, foi efetuada

a conversão automática da imagem de 16 para 8 bits. O *software* PCI possui uma função específica para esse tipo de reamostragem, denominada quantização normalizada (NQ – *normalized quantization*). Além disso, o tamanho do pixel original da imagem JERS (12,5 m) foi reamostrado para 18 m, que equivale, efetivamente, à resolução espacial da imagem.

Os dados de efemérides incluem informações sobre o modelo da Terra, sobre a órbita e sobre o sensor. Estes dois últimos encontram-se no arquivo *header* (cabeçalho), conhecido também como segmento *orbit*, que acompanha a imagem (ANDRADE, 2000). Este segmento foi lido e interpretado pelo *software* PCI (v. APÊNDICES).

O modelo da Terra foi baseado no Sistema Geodésico Sul Americano – SAD 69, com as seguintes características:

- a) elipsóide de referência – UGGI 67 (recomendado pela União Geodésica e Geofísica Internacional em 1967);
- b) origem das coordenadas (Datum planimétrico) – vértice Chuá (MG).

Foram definidos 3 pontos adicionais àqueles já coletados para a correção geométrica (v. item 3.3.1.1.1). O exame dos pontos de controle e dos seus respectivos desvios da raiz quadrada média (RMS) em relação à localização verdadeira determinou sua permanência ou exclusão do modelo.

A segunda etapa do algoritmo de ortorretificação foi executada através do módulo SRORTHO (*Satellite Radar ORthorectification*), usando o modelo do satélite e o modelo digital de elevação (DEM).

Para a geração do modelo digital de elevação foi utilizado um arquivo de altimetria (Fig. 16), em formato *dxf*, contendo curvas de nível e pontos cotados, obtidos através de restituição aerofotogramétrica. No *software* SPRING selecionou-se, inicialmente, a opção de geração de grade triangular, com triangulação do tipo Delaunay, sem linhas de quebra. Em seguida a grade triangular (TIN) foi usada como entrada de dados no processo de geração de grade regular, definindo-se uma resolução de 18 m e um interpolador do tipo linear. Segundo SPRING (1998b), na interpolação

linear um plano é ajustado para cada retalho triangular da grade, determinando-se, assim, os valores de z em cada posição (x,y) dentro do triângulo.

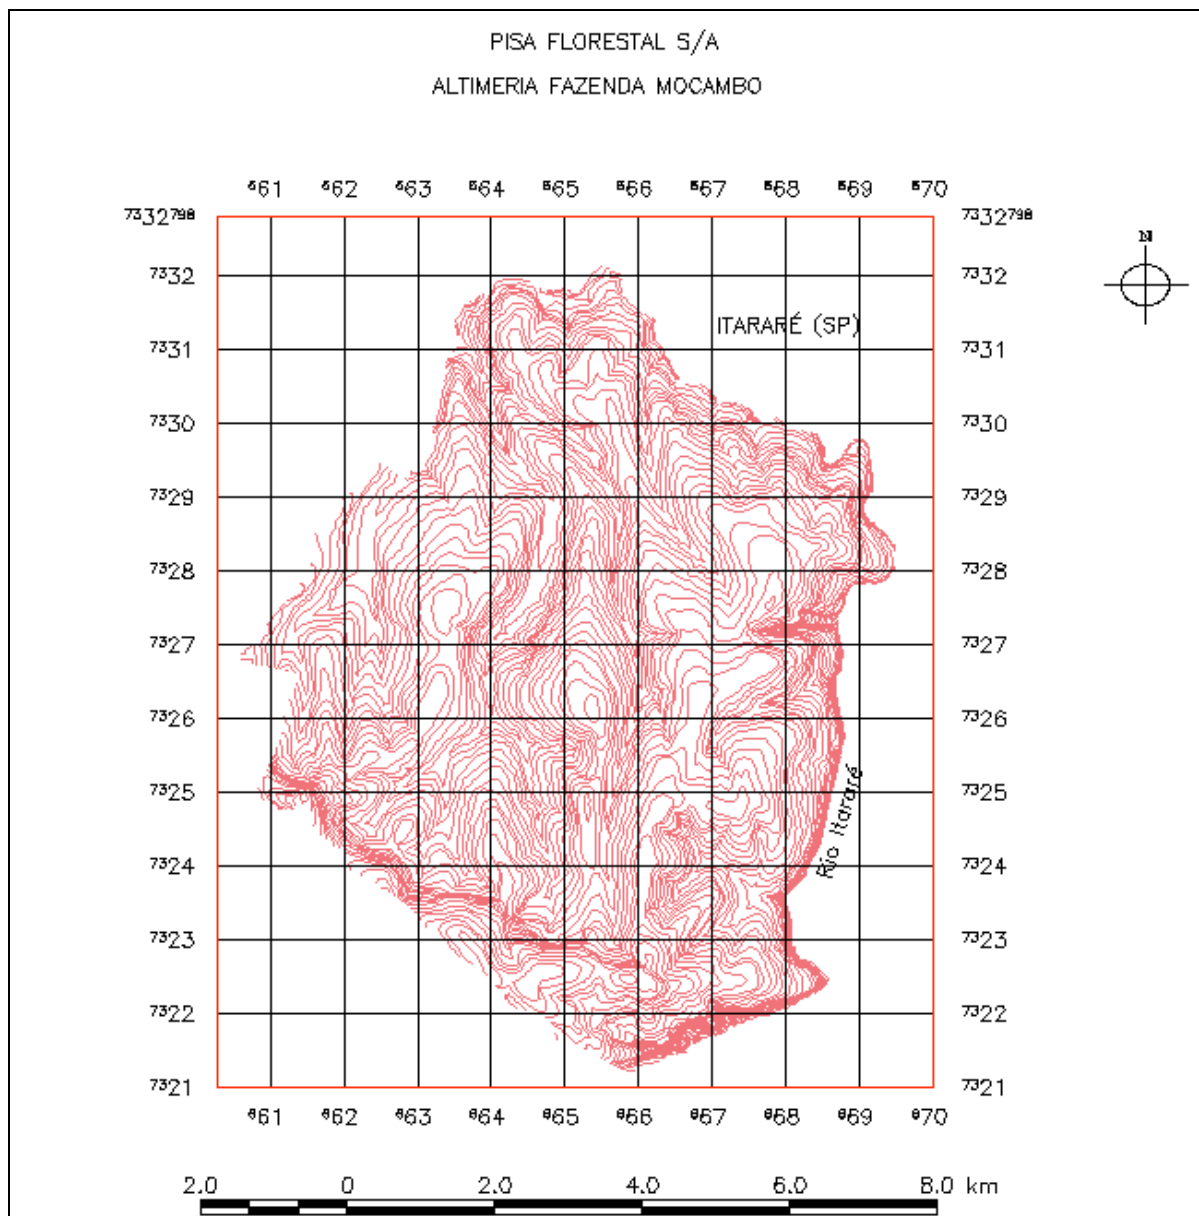


FIGURA 16 – ARQUIVO DE ALTIMETRIA DA ÁREA DE ESTUDO
FONTE: CADASTRO PISA FLORESTAL S/A

A partir da grade regular foi obtida uma imagem em nível de cinza que corresponde ao *raster DEM*. Para tanto foi empregada a opção “Geração de Imagem MNT – nível de cinza”, do *software SPRING*, sendo produzida uma imagem com a

mesma resolução da grade original, ou seja, 18 m. A imagem foi exportada em formato *tif* para facilitar operações subseqüentes no *software* PCI.

O modelo matemático empregado na ortorretificação exigiu o uso da cena inteira e não apenas do recorte contendo a área de estudo. No entanto como o arquivo de altimetria correspondia apenas à área da empresa, foi efetuada uma máscara no *raster* DEM, utilizando-se, para isso, um outro arquivo vetorial registrado e superposto à imagem do DEM, contendo os limites da área de estudo dentro da Fazenda Mocambo.

Como o DEM se encontrava em formato *raster*, sendo os valores de elevação representados por níveis de cinza, foi necessário definir valores de escala e *offset*, para que os dados de altimetria pudessem ser interpretados pelo algoritmo. Através do exame do arquivo original com as curvas de nível e os pontos cotados foram determinadas as altitudes mínima e máxima ocorrentes na área de estudo. Excetuando-se os valores extremos (0 e 255), correspondentes ao preto e ao branco absoluto, respectivamente, a diferença em termos de elevação está compreendida entre 254 níveis de cinza. Considerando que a porção mais baixa da fazenda estava situada a 590 m acima do nível do mar e que o ponto mais alto era equivalente a 1040 m, determinou-se um fator de escala igual a 1,77, ou seja, a variação unitária no nível de cinza correspondia a 1,77 m de variação na altitude. O valor obtido para o *offset* foi igual a 332, calculado através da seguinte fórmula:

$$\text{Offset} = \frac{(\text{elevação mínima} - \text{escala})}{\text{escala}}$$

Durante a execução da reamostragem no módulo SRORTHO foi aplicado um filtro para redução do *speckle*. Utilizando o método do vizinho mais próximo para encontrar as coordenadas na imagem de entrada, o programa aplicou o filtro selecionado aos pixels vizinhos para encontrar o valor filtrado. Dentre os filtros disponíveis (*Gamma*, *Enhanced Frost*, *Enhanced Lee* e *Median*) escolheu-se o mesmo que já havia sido selecionado nas etapas anteriores à correção geométrica.

3.3.1.2 Processamento

3.3.1.2.1 Segmentação

A imagem ortorretificada, em formato TIFF, foi importada para o *software* SPRING onde foi submetida ao processo de segmentação como uma etapa prévia à classificação não-supervisionada. O algoritmo utilizado baseou-se no método de crescimento de regiões, partindo de um “pixel-semente” e, posteriormente, agrupando os pixels adjacentes que possuem características similares e que satisfazem o critério de similaridade (NASCIMENTO e ALMEIDA FILHO, 1996). Foram testadas diversas combinações dos parâmetros “similaridade” e “área”. A similaridade é o limiar abaixo do qual duas regiões são consideradas similares e, então, agrupadas. Corresponde ao valor da distância euclidiana mínima entre as médias das regiões consideradas. O limiar de área é o número mínimo de pixels para que uma região seja individualizada.

3.3.1.2.2 Classificação não-supervisionada

Inicialmente foi efetuada uma classificação não-supervisionada sobre a imagem de radar, testando-se dois algoritmos: Isodata e K-médias. Além disso foi testado o algoritmo Ioseg, disponível no *software* SPRING, utilizado para classificar regiões de uma imagem segmentada. Este é um algoritmo de agrupamento de dados não-supervisionado, aplicado sobre o conjunto de regiões, que por sua vez são caracterizadas por seus atributos estatísticos de média e matriz de covariância e, também, pela área. É uma técnica para classificação que procura agrupar regiões, a partir de uma medida de similaridade entre elas. A medida de similaridade utilizada consistiu na distância de Mahalanobis entre a classe e as regiões candidatas à relação de pertinência com esta classe (SPRING, 1998a).

A classificação não-supervisionada foi efetuada com o objetivo de se utilizar os *clusters* assim gerados como amostras de treinamento na classificação

supervisionada.

3.3.1.2.3 Classificação supervisionada

Na classificação supervisionada, foram testados quatro algoritmos: distância mínima, máxima verossimilhança, modas condicionais iterativas (*Iterated Conditional Modes* - ICM) e *Bhattacharyya*. Foram definidas áreas de treinamento englobando todas classes de interesse, utilizando como referência os dados auxiliares (mapas, fotos aéreas e cadastro florestal). No caso do algoritmo de *Bhattacharyya*, as amostras foram definidas iterativamente com base nos polígonos gerados pela segmentação.

3.3.1.2.4 Avaliação da acuracidade temática

Os melhores resultados obtidos com as classificações foram avaliados em função da matriz de erros e do coeficiente κ , que são indicadores da acurácia temática (v. item 2.4.5).

3.3.1.2.5 Conversão via tela

Imagens de radares orbitais, obtidas em curto espaço de tempo e interpretadas visualmente em meio digital, podem ser bastante adequadas à atualização de mapas e estimativa de áreas na empresa florestal. Uma das técnicas mais utilizadas é empregar a imagem de satélite como fundo e vetorizar em tela as novas informações, no processo conhecido como *heads-up digitizing* (USDA FOREST SERVICE, 1995).

Visando-se avaliar o método de conversão via tela para a obtenção de estimativas de áreas de talhões a partir da interpretação visual da imagem JERS1-SAR, foi efetuada uma comparação entre áreas de polígonos vetorizados sobre a imagem e áreas reais, obtidas dos mapas topográficos (Fig. 17) e cadastro florestal da empresa. As quadrículas observadas na Figura 17 correspondem a áreas de 1000 m por 1000 m (100 ha), estabelecidas por ocasião da implantação dos povoamentos.

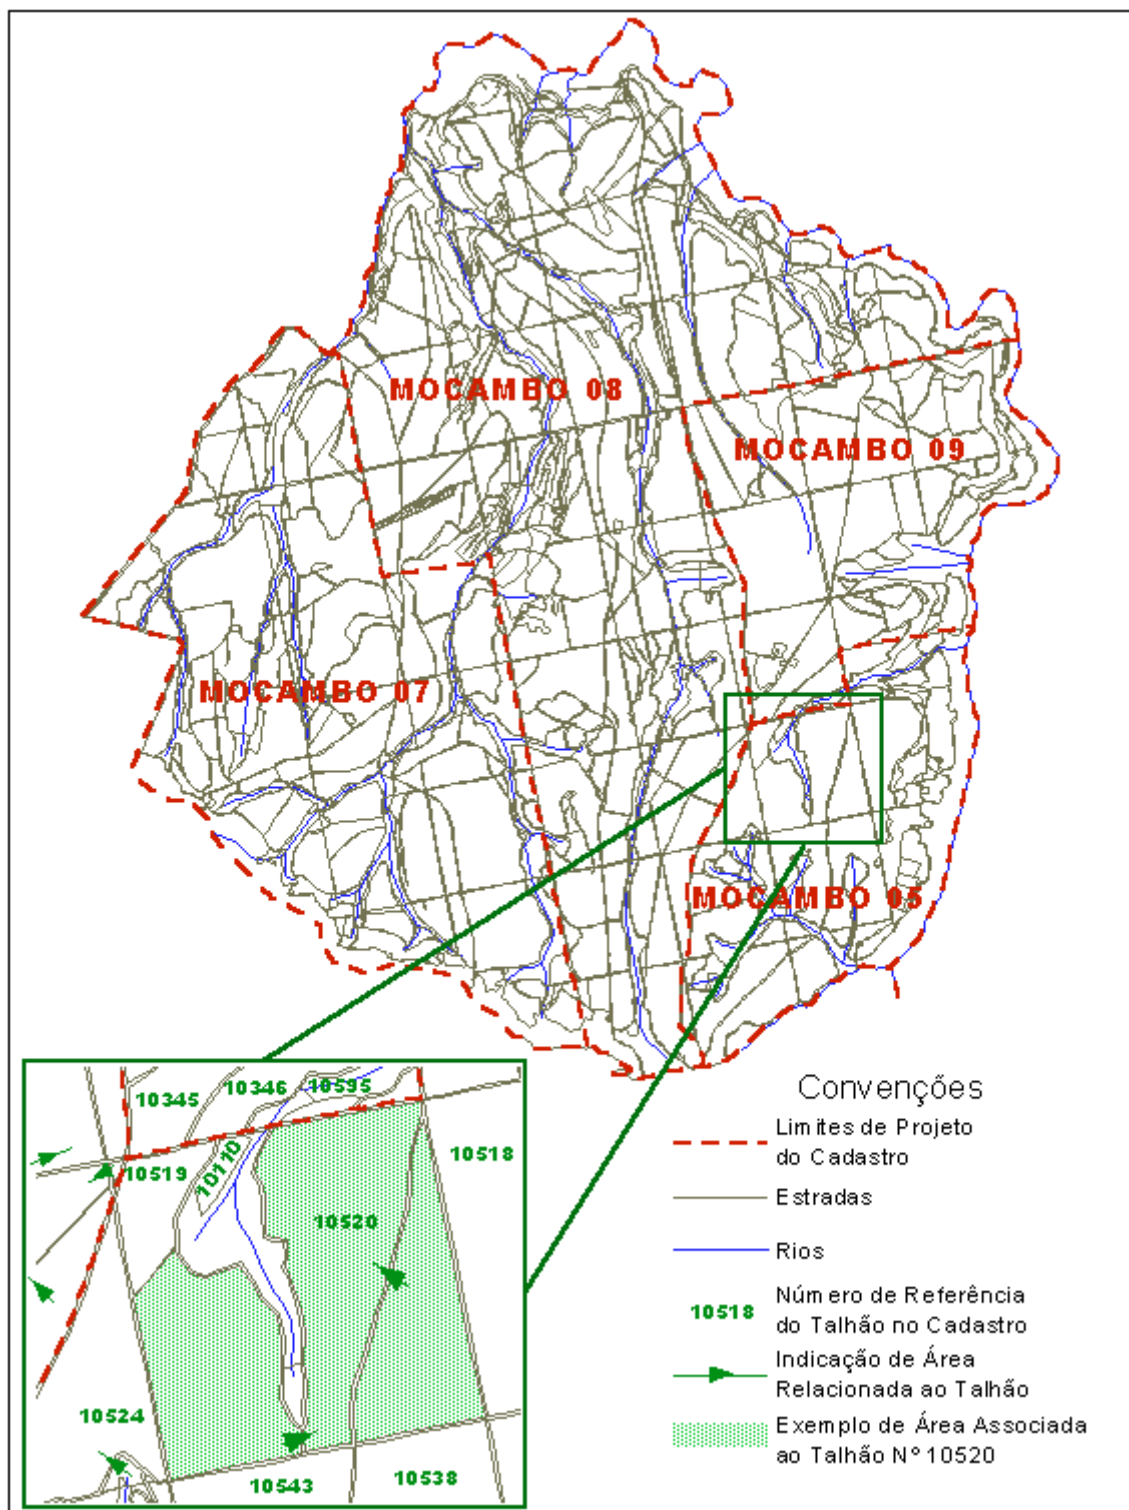


FIGURA 17 – ARQUIVO VETORIAL CONTENDO LIMITES DOS TALHÕES, ESTRADAS E ACEIROS DE PARTE DA ÁREA DE ESTUDO

FONTE: Cadastro Pisa Florestal S/A

Primeiramente foi necessário identificar todos os talhões da área de estudo e seus respectivos limites na imagem SAR. Para tanto foram empregados dados auxiliares, tais como fotografias aéreas 1:25.000 e 1:50.000, adquiridas, respectivamente, 6 anos antes e 2 anos depois da tomada da imagem pelo satélite, composições coloridas LANDSAT-5 TM, dados do cadastro florestal e, também, os arquivos vetoriais contendo os limites dos talhões.

Foram vetorizados, diretamente na tela, sobre a imagem JERS, o perímetro de 10 talhões-amostra da área de estudo. Utilizando-se a ferramenta para medição de polígonos do *software* ENVI, foram estimadas as áreas de cada talhão em metros quadrados. Os resultados foram armazenados em arquivo texto.

A diferença percentual entre áreas estimadas e áreas verdadeiras, obtidas do cadastro florestal, foi calculada através da seguinte fórmula:

$$Dif.(%) = \frac{(\text{área estimada} - \text{área real})}{\text{área real}} \times 100$$

Para comparar as áreas estimadas e as áreas reais empregou-se o teste *t* emparelhado, que é utilizado quando as observações de duas populações de interesse são coletadas em pares (área do mesmo talhão, real e estimada), obtendo-se, assim, amostras denominadas dependentes ou emparelhadas.

O teste da hipótese H_0 de que a média da distribuição das diferenças (μ_D) entre áreas reais e estimadas é igual a zero baseia-se na estatística de teste (WERKEMA, 1996):

$$t_o = \frac{\bar{D}}{s_D / \sqrt{n}}, \text{ em que}$$

$$\bar{D} = \frac{1}{n} \sum_{i=1}^n D_i \text{ é a média da amostra das diferenças;}$$

$$s_D^2 = \frac{1}{n-1} \sum_{i=1}^n (D_i - \bar{D})^2 \text{ é a variância da amostra das diferenças;}$$

D_i = diferença percentual entre a área real e a estimada, para o talhão i ;

n = tamanho da amostra das diferenças.

A hipótese $H_0: \mu_D = 0$ deverá ser rejeitada se:

$$t_o > t_{\alpha/2; n-1} \quad \text{ou} \quad t_o < -t_{\alpha/2; n-1}$$

3.3.2 Imagens LANDSAT-5 TM

3.3.2.1 Pré-Processamento

3.3.2.1.1 Recorte da área

A área de estudo foi localizada visualizando-se a banda TM4 da imagem LANDSAT e, em seguida, foi efetuado um recorte sobre a cena, repetindo-se, depois, o procedimento para as outras 5 bandas.

3.3.2.1.2 Correção atmosférica

O efeito atmosférico dominante é a dispersão da radiação por partículas, especialmente na região visível do espectro (CHAVEZ JR, 1988). Devido a isso, torna-se muitas vezes necessário pré-processar as imagens LANDSAT TM, corrigindo os valores digitais para a atenuação atmosférica. VERBYLA (1995) relaciona quatro tipos de aplicações onde as correções para efeitos atmosféricos são extremamente importantes:

- a) aplicações aquáticas;
- b) razão de bandas;
- c) aplicações multitemporais;
- d) aplicações com múltiplos sensores.

Um dos métodos de correção radiométrica mais simples é o do mínimo do histograma (CHAVEZ JR, 1988), em que o algoritmo procura por valores digitais em áreas de reflectância sabidamente iguais a zero, como a água limpa profunda na região do infravermelho próximo do espectro. Como o efeito da dispersão atmosférica se

manifesta em valores digitais superiores aos que seriam esperados para a reflectância dos alvos, qualquer valor acima de zero observado nessas áreas é devido à dispersão atmosférica e deve ser subtraído de todos os pixels em cada banda individual (LILLESAND e KIEFFER, 1994).

CAMPBELL (1996), contudo, afirma que a decisão sobre a necessidade de se efetuar correções atmosféricas ou não, deve basear-se nas estatísticas de cada cena, principalmente na verificação das médias e variâncias, além da avaliação dos histogramas de frequência que sugiram baixa qualidade de imagem.

Na cena LANDSAT TM, através de análise visual, foram delimitados os corpos d'água existentes e, também, áreas de sombreamento junto à margem direita do *canyon* do Rio Itararé, com o objetivo de verificar os mínimos valores de DN's para a aplicação da técnica de correção para os efeitos atmosféricos.

3.3.2.1.3 Correção geométrica

A imagem LANDSAT TM utilizada nesta pesquisa foi disponibilizada com correções geométricas básicas, incluindo-se aí as correções para as distorções sistemáticas (v. item 2.4.1.2). Para efetuar a geocodificação foi utilizado o método "imagem-mapa", empregando-se um mapa planimétrico georreferenciado, em meio digital, com escala original igual a 1:10.000, elaborado a partir de aerolevanteamento efetuado em 1989, onde foram selecionados 12 pontos de controle perfeitamente identificáveis na imagem da banda TM4 e no mapa. A experiência prática sugere que sejam tomados de 10 a 15 pontos de controle para efetuar o georreferenciamento em se tratando de imagens LANDSAT TM ou MSS ou SPOT e áreas relativamente pequenas, de até 1024^2 pixels (MATHER, 1999). Empregou-se uma transformação polinomial de primeira ordem e reamostragem por interpolação bilinear (EASTMAN, 1998), sendo a precisão da função de mapeamento avaliada através do erro da raiz quadrada média - RMS (v. item 3.3.1.1.1).

3.3.2.2 Processamento

As composições coloridas consistem em conjuntos de três bandas, sendo cada uma atribuída a um dos canais RGB, disponíveis para visualização no sistema de processamento de imagens utilizado. Foram testadas diversas composições e selecionadas aquelas que melhor discriminaram os diferentes tipos florestais existentes na área. Operações de realce de imagens, disponíveis nos *software* utilizados nesta pesquisa, foram aplicadas às melhores composições, com a finalidade de produzir imagens mais facilmente interpretáveis e realçar as feições de interesse.

O baixo nível de saturação nas imagens LANDSAT TM é responsável pelos característicos tons “pastel” apresentados pelas composições coloridas (SABINS, 1997). Alguns dos *software* empregados permitiram a aplicação automática de técnicas de transformação no espaço de cores com o objetivo de realçar a imagem. O processo consistiu, inicialmente, na transformação das bandas das composições coloridas selecionadas do espaço RGB para o espaço IHS. Em seguida foi aplicado um contraste do tipo “gaussiano” na banda “saturação”, para que fosse preenchida toda a sua amplitude de valores. Na última etapa efetuou-se a transformação inversa para o espaço RGB.

Outras transformações de imagens foram aplicadas aos dados originais, tais como a análise por componentes principais (ACP), razão de bandas e índice de vegetação de diferença normalizada (NDVI). A transformação por componentes principais foi efetuada, inicialmente, envolvendo o conjunto das seis bandas LANDSAT TM (padrão) e, depois, subconjuntos (seletiva), com as bandas na região do infravermelho (TM4, TM5, TM7). Também foi testada a componente principal seletiva envolvendo as bandas (TM3, TM4, TM5), por ser esta uma das composições coloridas RGB mais frequentemente empregadas nas aplicações florestais de sensoriamento remoto e por ser um produto bastante comercializado pelos representantes autorizados de imagens de satélite.

Quanto à classificação temática, para as imagens LANDSAT foram aplicados os mesmos algoritmos empregados para a imagem JERS.

As bandas originais ou transformadas que proporcionaram a melhor separabilidade entre as classes existentes na área de estudo foram selecionadas para a aplicação da técnica de segmentação.

O treinamento não-supervisionado foi empregado como uma análise exploratória dos dados, para investigar a possibilidade das classes existentes serem discriminadas espectralmente. Além disso, objetivou-se utilizar os *clusters* como amostras de treinamento na classificação supervisionada.

Para o treinamento não-supervisionado foram empregados os algoritmos K-médias, Isodata e Isoseg. Com base na “verdade de campo” e utilizando dados auxiliares como fotografias aéreas e mapas de vegetação da empresa, para o algoritmo K-médias foi definido um número máximo de 5 classes ou *clusters*.

No treinamento supervisionado foram empregadas regras de classificação paramétrica (algoritmo da distância mínima, máxima verossimilhança e ICM), incluindo na classificação as seis bandas LANDSAT TM disponíveis. As áreas de treinamento ou “regiões de interesse” foram definidas tendo como fundo as composições coloridas que melhor discriminaram as classes previamente estabelecidas. Além disso, foi testado um classificador por região, com base na imagem segmentada, utilizando a distância de *Bhattacharyya*.

A acurácia temática foi avaliada em função da matriz de erros (acurácias geral, do produtor e do usuário) e do coeficiente κ (v.item 2.4.5).

3.3.3 Fusão de Imagens

A primeira etapa para a fusão de imagens dos sensores JERS-1 e LANDSAT TM consistiu no registro entre as duas imagens, no procedimento denominado mestre/escravo (*master-slave*). A imagem de referência “mestre” (*master*) foi a do sensor JERS1-SAR, uma vez que a mesma foi ortorretificada e possui, portanto, menores distorções quanto ao relevo. A imagem “escravo” (*slave*) foi a LANDSAT-5 TM.

No registro “imagem-a-imagem” foram selecionados pontos de controle facilmente identificáveis, especialmente os cruzamentos das estradas que dividem os talhões. As coordenadas destes pontos na imagem JERS e na LANDSAT constituíram o conjunto de dados para estimar os coeficientes da função de mapeamento (polinomial de primeira ordem), cuja precisão foi avaliada segundo os critérios definidos no item 3.3.1.1.1. No processo de reamostragem dos pixels da imagem LANDSAT foi empregado o método da interpolação bilinear, que evita a ocorrência de alterações significativas nos níveis de cinza da imagem original (SILVA JR., 1999).

Foram testadas as técnicas de fusão de dados mais comumente empregadas, entre elas a combinação simples de bandas (SILVA JR., 1999), transformações estatísticas como as componentes principais e a transformação IHS das composições coloridas originais ou das componentes principais (SOARES, 1997; HARRIS et al., 1990; VALLE, 1997).

O(s) melhor(es) produto(s) híbrido(s) foram, então, utilizados em classificações não-supervisionadas e supervisionadas, com as mesmas abordagens efetuadas para as imagens de cada sensor separadamente.

As acurácias temáticas obtidas com a classificação da imagem JERS, da imagem LANDSAT TM e do produto híbrido foram comparadas entre si com a finalidade de avaliar os possíveis ganhos da fusão de dados.

4 RESULTADOS E DISCUSSÃO

4.1 IMAGEM JERS1-SAR

4.1.1 Pré-processamento

4.1.1.1 Correções radiométricas e geométricas

Após o recorte, o tamanho da imagem JERS-1 SAR ficou reduzido a 1131 linhas e 951 colunas, facilitando a manipulação de arquivos.

Os diversos filtros testados produziram imagens com diferentes graus de redução do *speckle*. Na análise visual foi considerado o binômio “redução do ruído/preservação de bordas” para a seleção do melhor algoritmo de filtragem. Nesse sentido o filtro de Frost, baseado no desvio-padrão dos níveis de cinza calculado entre os pixels pertencentes à janela 5x5, foi considerado o melhor filtro, pois conseguiu diminuir sensivelmente o ruído e, ao mesmo tempo, preservar a nitidez e os detalhes da imagem (Fig. 18).

Na correção geométrica por transformação polinomial de 3^a ordem obteve-se um erro da raiz quadrada média (RMS) igual a 0,2817 pixels, o que equivale a um erro de 3,5 m no terreno, uma vez que, nessa etapa do processamento, o tamanho do pixel ainda não havia sido reamostrado de 12,5 m para 18 m.

Mesmo considerando o valor do RMS plenamente satisfatório, a superposição do arquivo vetorial (Fig. 17) sobre a imagem corrigida revelou deslocamentos significativos (3-4 pixels) entre as feições do mapa e da imagem, o que denota baixa acuracidade geométrica. Os deslocamentos foram maiores nas regiões de relevo mais ondulado. Mesmo havendo pouca variação de altitude na área de estudo comprovou-se, então, ser necessária a utilização de um modelo digital do terreno para corrigir as distorções pelo relevo.




FIGURA 18 – SUB-CENA DA IMAGEM JERS1-SAR FILTRADA (FILTRO DE FROST, 5 X 5), CONTENDO A ÁREA DE ESTUDO

4.1.1.2 Ortorretificação

As curvas de nível do arquivo de altimetria (Fig. 16) foram utilizadas para a geração do modelo digital de elevação (DEM), com cada nível de cinza correspondendo a 1,77 m de altitude.

Adicionalmente, empregando-se a opção *density slicing* (fatiamento) do software ENVI, foi possível gerar o mapa hipsométrico da Fazenda Mocambo, mostrado na Figura 19. Embora o DEM original tenha sido usado, efetivamente, no processo de orrorretificação, o fatiamento em classes de altitude proporcionou melhor interpretabilidade do relevo, gerando um produto mais atrativo e visualmente agradável.

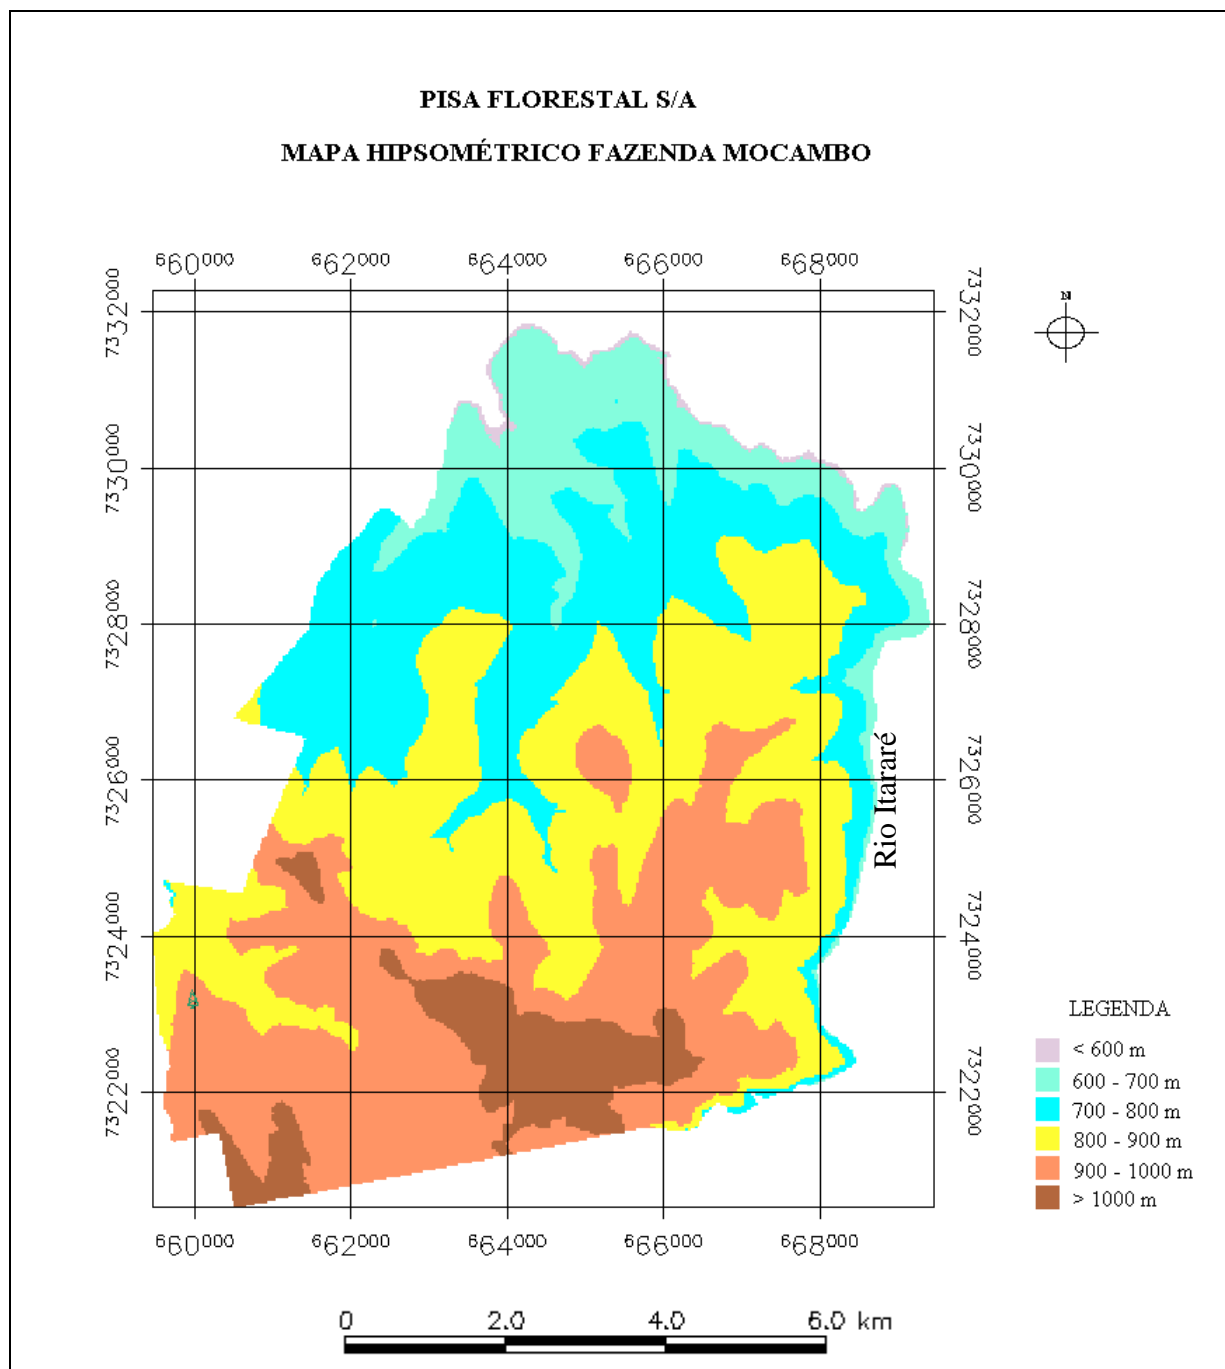


FIGURA 19 – MAPA HIPSOMÉTRICO DE PARTE DA FAZENDA MOCAMBO, CONTENDO A ÁREA DE ESTUDO

Dos quinze pontos de controle selecionados na imagem e no arquivo vetorial dos talhões, doze foram efetivamente empregados no ajuste do modelo do satélite. Na Tabela 7 são apresentados os GCPs selecionados, suas coordenadas UTM estimadas e os desvios da raiz quadrada média (RMS) por ponto e médio para todos os pontos.

Pôde-se constatar que o ajuste geral foi satisfatório, obtendo-se um RMS igual a 13,61 m, inferior, portanto, à resolução da célula do DEM, que é de 18 m.

TABELA 7 – PONTOS DE CONTROLE (GCPs) EMPREGADOS NO AJUSTE DO MODELO DO SATÉLITE

N° GCP	GCP CALCULADO		RESÍDUOS (metros)		
	X	Y	X	Y	RMS
1	666073.04	7328726.49	-4.26	-1.33	4.46
2	662920.06	7329175.39	-10.14	27.41	29.23
3	663131.88	7328151.79	-5.62	-6.52	8.60
4	660565.16	7326817.92	4.85	-13.30	14.16
6	668482.05	7329223.45	2.52	6.21	6.70
7	666715.08	7330505.58	-6.03	-9.14	10.95
8	665287.33	7330642.98	14.29	-6.06	15.52
10	663402.56	7325327.94	15.17	-2.31	15.34
11	660364.31	7321480.07	-3.96	7.79	8.74
12	663513.92	7321098.60	0.71	-5.65	5.69
13	665842.68	7325625.27	-10.89	-0.14	10.89
14	667395.63	7324915.03	3.37	3.02	4.52
		RMS	8.52	10.61	13.61

Na Figura 20 é apresentado o recorte da imagem JERS1-SAR ortorretificada, com reamostragem dos pixels para 18 m, contendo a área de estudo e os GCPs utilizados para a ortorretificação. Pode-se notar que algumas das feições foram bem realçadas, principalmente a estrada principal que atravessa a área no sentido norte-sul e as quadrículas dos talhões. Comparando-a com a Figura 18, que contem a imagem original, observa-se a rotação sofrida pela imagem ortorretificada. Durante o procedimento de reamostragem foi aplicado o filtro *Enhanced Frost*, em janela 5 x 5, uma vez que este já havia sido selecionado como o melhor filtro nas etapas do processamento anteriores à correção geométrica.




FIGURA 20 – IMAGEM JERS1-SAR, ORTORRETIFICADA, CONTENDO A ÁREA DE ESTUDO E PONTOS DE CONTROLE (GCPs)

4.1.2 Processamento

4.1.2.1 Segmentação de imagens

Durante o processo de segmentação foram testadas as seguintes combinações de limiares de similaridade e área, respectivamente:

- a) 8 e 10 (*default* do programa SPRING);
- b) 8 e 30;
- c) 10 e 30;
- d) 15 e 30;
- e) 18 e 30;
- f) 20 e 30;
- g) 30 e 30.

Partiu-se, inicialmente, da combinação *default*, com limiar de similaridade igual a 8 e limiar de área igual a 10 pixels. O tamanho do pixel na imagem JERS ortorretificada era 18 m, o que equivale a dizer que áreas contendo 10 pixels correspondem a 0,32 ha. Consultando-se o cadastro florestal da empresa verificou-se que raramente existem talhões inferiores a um hectare, de forma que se estabeleceu como área mínima o valor de 30 pixels.

Uma vez fixado o limite de área, variou-se o limiar de similaridade, sendo observados, a cada nova imagem gerada, o número de regiões criadas. Limiares mais baixos, como 8, por exemplo, produziram um número excessivo de regiões, enquanto que limiares mais altos, como 30, por exemplo, geraram poucas regiões, agrupando tipologias claramente individualizadas na análise visual.

Das várias combinações testadas durante o processo de segmentação, considerou-se como a melhor a combinação do limiar de similaridade igual a 20 e do limiar de área igual a 30 pixels. Esses resultados são similares aos encontrados por OLIVEIRA (2000), que determinou limiares de similaridade ótimos iguais a 30 e

limites de área iguais a 30 na segmentação de imagens-diferença da Floresta Nacional de Irati-PR.

Na Figura 21 (a) são apresentados os polígonos (linhas vermelhas) criados pelos limiares de segmentação selecionados, sobrepostos à imagem JERS. A Figura 21 (b) mostra uma sub-área ampliada da mesma imagem contendo talhões de *Eucalyptus spp* perfeitamente delineados através do processo de segmentação.




FIGURA 21 – (a) IMAGEM JERS1-SAR SEGMENTADA, COM LIMIAR DE SIMILARIDADE 20 E LIMIAR DE ÁREA IGUAL A 30; (b) AMPLIAÇÃO DE TALHÕES DE *Eucalyptus spp*

Através da análise da Figura 21 pode-se constatar que a técnica de segmentação permitiu delimitar talhões de *Eucalyptus spp*, *Pinus spp*, mata nativa (com menor frequência) e solo exposto. Os povoamentos de *Pinus spp* aparecem em tons mais claros, como uma grande e única região, dominando a imagem. Não foi possível delimitar talhões de *Pinus* de diferentes espécies, densidades ou idades.

4.1.2.2 Classificação não-supervisionada

A classificação não-supervisionada foi aplicada em duas abordagens distintas. A primeira envolveu algoritmos de classificação por pixel (K-médias e Isodata) do *software* ENVI, enquanto que a segunda se baseou num classificador por regiões (Isoseg) do *software* SPRING.

Para poder avaliar o desempenho dos classificadores definiu-se cinco classes (*Pinus spp*, *Eucalyptus spp*, mata nativa, solo exposto e água) com base no cadastro florestal, fotos aéreas e demais dados auxiliares. Procurando-se associar essas classes às classes espectrais geradas pelo algoritmo K-médias, observou-se que houve pouca separabilidade entre classes.

A aplicação do algoritmo Isodata apresentou uma melhora nos resultados, talvez devido à incorporação de mais um parâmetro, a distância mínima entre as médias das classes, não considerada pelo K-médias. Essa distância foi definida inicialmente como 20, tomando-se por base o limiar de similaridade estabelecido no processo de segmentação. No entanto a imagem classificada apresentou o efeito indesejável da inclusão de inúmeros polígonos de menores dimensões dentro das classes maiores e mais homogêneas. Além disso, observou-se que as classes espectrais geradas sofreram grande influência da direção de iluminação do feixe radar. Áreas pertencentes a uma mesma tipologia foram classificadas como categorias diferentes, conforme se localizassem em aclives ou declives.

Tendo-se testado vários parâmetros de entrada para o algoritmo Isodata, concluiu-se que os melhores resultados foram obtidos com uma distância mínima igual a 30 e um número de classes pré-estabelecido variando de quatro a cinco. Utilizou-se o recurso de pós-classificação disponível no *software* ENVI (opção *clump* – agrupar), para reduzir o efeito *salt-and-pepper*, bastante comum em imagens classificadas.

Na Figura 22 é apresentado o resultado da classificação não-supervisionada, onde as quatro classes espectrais geradas foram associadas às quatro tipologias predominantes na área de estudo. Pode-se observar que a maior parte dos reflorestamentos é constituída por talhões de *Pinus spp* (áreas **3**), seguindo-se alguns

talhões de *Eucalyptus spp* (áreas 1) e áreas de preservação permanente, com mata nativa. As áreas de solo exposto (áreas 2) na verdade representam povoamentos de *Pinus spp* recém-implantados, onde a resposta espectral do solo é predominante sobre a resposta das árvores jovens. O algoritmo Isodata não conseguiu diferenciar as classes *Eucalyptus spp* (áreas 1) e *Pinus spp* com menos de três anos de idade (área 3a). Deve-se ressaltar, também, que foram gerados muito mais polígonos classificados como mata nativa do que o efetivamente existente na área.

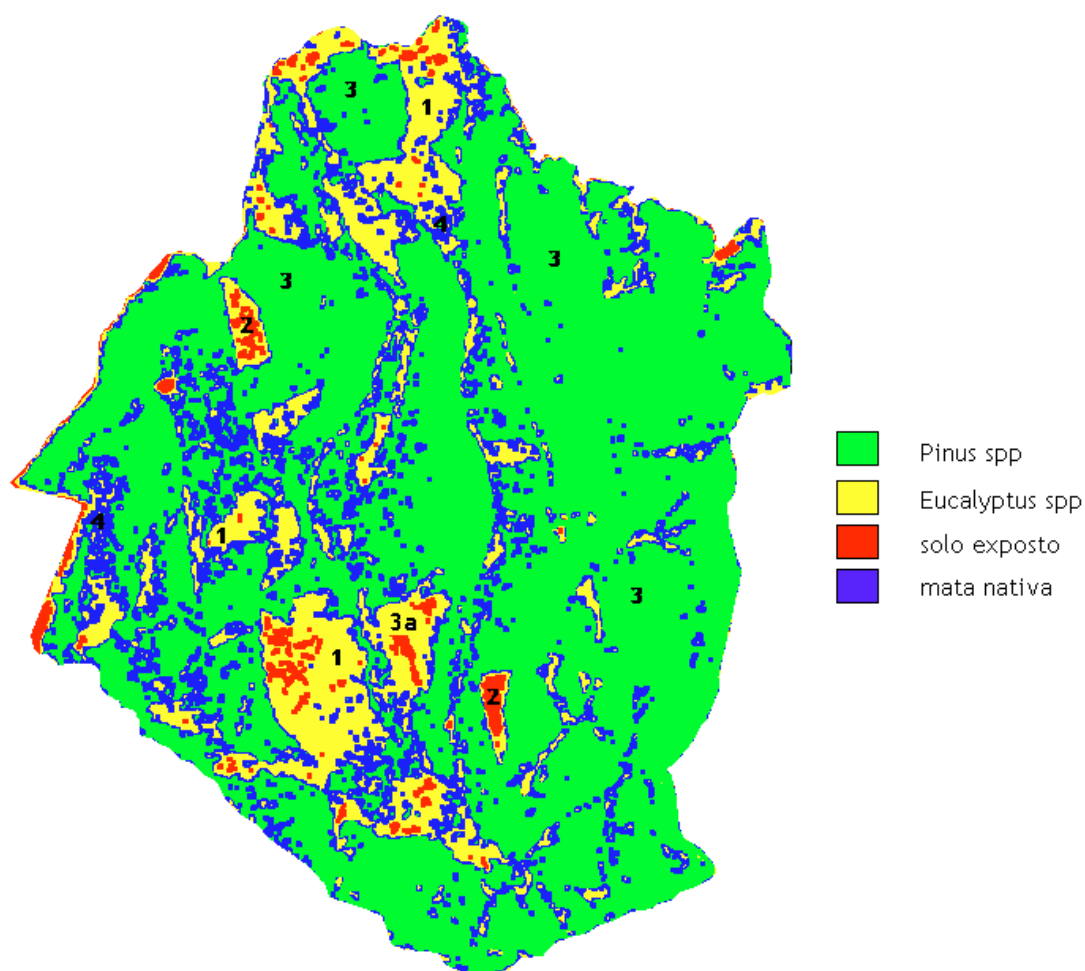


FIGURA 22 – CLASSIFICAÇÃO NÃO-SUPERVISIONADA DA IMAGEM JERS1-SAR (ALGORITMO ISODATA)

A classificação não-supervisionada por regiões baseou-se na imagem JERS1-SAR segmentada para a qual se considerou o limiar de similaridade igual a 20 e o limite mínimo de área igual a 30 pixels (Fig. 21). Nesse algoritmo é solicitada, também, a definição de um limiar de aceitação para que uma região seja incorporada a uma determinada classe. Foram testados limiares de 99,9%, 99%, 95%, 90% e 75%. Quanto maior o limiar, menor o número de classes criadas. Para o limiar de 95% foram geradas 4 classes, porém apenas três puderam ser associadas às classes temáticas presentes na área. Quando se utilizou um limiar de 90%, da mesma forma foram criadas 4 classes, mas, a cada uma, correspondeu uma classe de informação. Este foi, portanto, o limiar de aceitação empregado na classificação pelo algoritmo Isoseg. Os outros limiares testados (75 %, 99 % e 99,9 %) geraram, respectivamente, sete, três e três classes.

Observando-se a Figura 23 constatou-se que povoamentos jovens de *Pinus spp* foram discriminados como áreas de solo exposto e também, em alguns casos, como áreas de *Eucalyptus spp*. Áreas de preservação permanente com mata nativa foram incluídas na mesma classe das florestas de *Eucalyptus spp*.

De um modo geral todos os algoritmos empregados na classificação não-supervisionada da imagem JERS1-SAR não trouxeram contribuição significativa na discriminação de novas classes tipológicas. Em função disso os polígonos gerados não foram aproveitados como amostras de treinamento para a classificação supervisionada, conforme se pretendia a princípio (classificação híbrida).

Uma das prováveis justificativas para os maus resultados obtidos com a classificação não-supervisionada é o fato de que, nessa abordagem, procura-se, *a posteriori*, fazer a correspondência entre as classes naturais ou espectrais e as classes de informação e isso nem sempre é fácil. Os *clusters* formados podem não ter significado porque representam classes mistas de diferentes materiais da superfície terrestre (JENSEN, 1996).

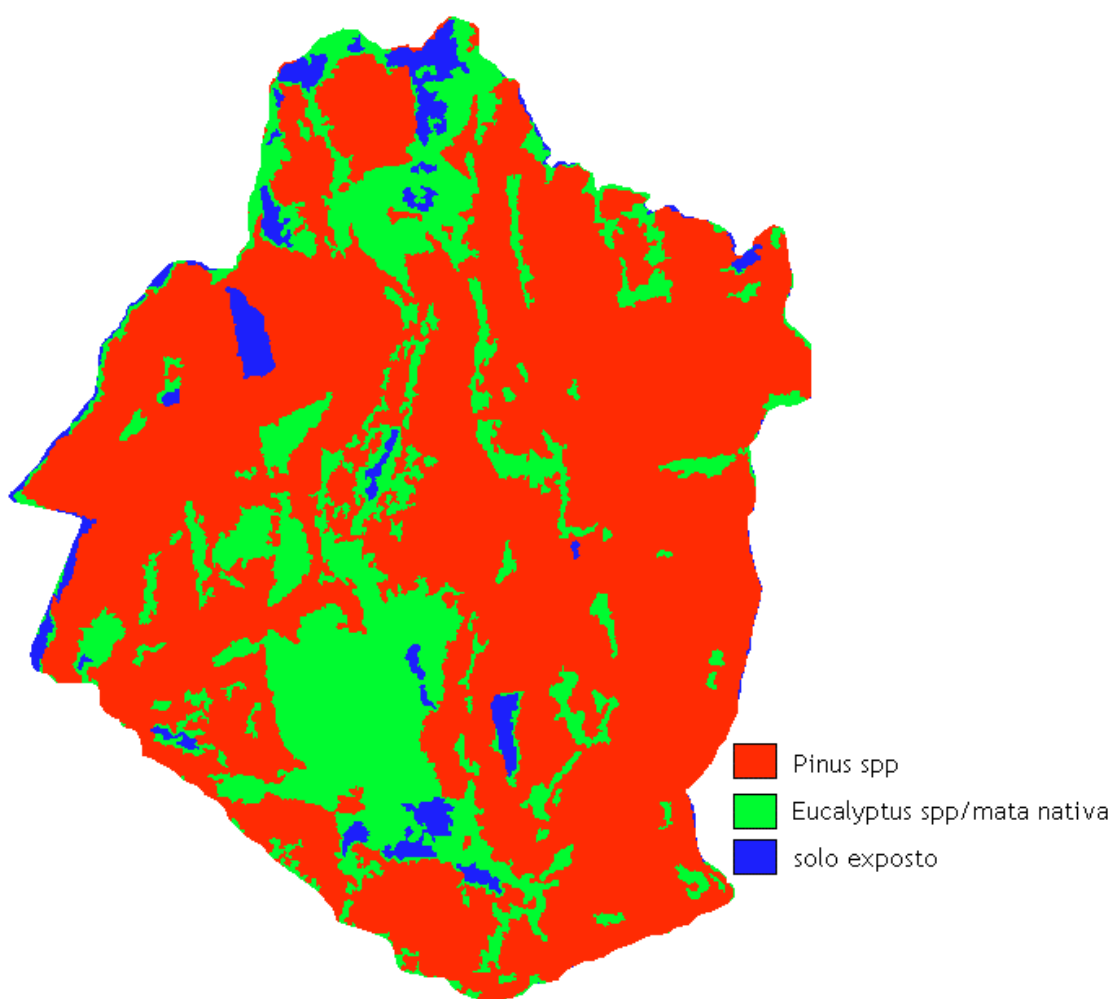


FIGURA 23 – CLASSIFICAÇÃO NÃO-SUPERVISIONADA DA IMAGEM JERS1-SAR SEGMENTADA (ALGORITMO ISOSEG)

4.1.2.3 Classificação supervisionada

Dos quatro algoritmos testados (distância mínima, máxima verossimilhança, ICM e *Bhattacharyya*), este último foi o que apresentou os melhores resultados. Isso, provavelmente, se atribui ao fato de que, além de tratar-se de um classificador por regiões, o algoritmo de *Bhattacharyya* utiliza como amostras os polígonos previamente criados no processo de segmentação da imagem.

A classificação utilizando o método da distância mínima apresentou confusão entre classes, principalmente entre mata nativa e *Eucalyptus spp*. Além disso, as

bordas das áreas de solo exposto ou de povoamentos de *Pinus* recém-implantados foram erroneamente classificadas como *Eucalyptus spp.* Tal resultado já era esperado, uma vez que esse algoritmo não considera a variabilidade espectral das classes de cobertura, mas apenas as suas médias.

Os resultados obtidos com o algoritmo da máxima verossimilhança não apresentaram melhoras significativas em relação ao da distância mínima, sendo que algumas áreas de solo exposto continuaram a ser confundidas com a classe “*Eucalyptus spp.*”.

Dentre os classificadores por pixel, considerou-se o classificador ICM como o mais eficiente, embora os resultados obtidos ainda não possuíssem a acurácia temática desejada. No entanto isto comprova a importância da informação contextual quando se classifica imagens de radar.

Na Figura 24 são apresentados os resultados da classificação supervisionada por regiões, empregando-se a distância de *Bhattacharyya*. Embora a confusão entre as classes tenha diminuído sensivelmente quando comparada àquela observada nos classificadores por pixel, ainda não foi possível obter a discriminação desejada para os tipos florestais existentes na área de estudo.

4.1.2.4 Acurácia temática

Para a avaliação da acuracidade temática da classificação por *Bhattacharyya* foram coletados cerca de 50 pontos por classe, perfazendo um total de 206 pontos de referência amostrados. Utilizou-se amostragem aleatória estratificada, sendo os estratos as classes existentes na área de estudo. Dentro de cada estrato os pontos foram escolhidos de forma aleatória. A localização exata de cada ponto foi obtida do arquivo vetorial contendo o mapa dos talhões e, em seguida, o mesmo ponto foi locado sobre o mapa derivado da classificação (Fig. 24). As concordâncias e não-concordâncias foram sumarizadas na matriz de erros (Tab. 8), a partir da qual calculou-se as acurácias geral, do produtor e do usuário (Tab. 9), bem como o Índice *kappa* (κ).




FIGURA 24 - CLASSIFICAÇÃO SUPERVISIONADA DA IMAGEM JERS1-SAR SEGMENTADA (ALGORITMO BHATTACHARYYA)

A acurácia geral da classificação por *Bhattacharyya* foi igual a 60,19%. Baseando-se na estatística κ calculada (0,4647) pode-se afirmar que a classificação efetuada é 46,47% melhor do que outra classificação obtida aleatoriamente. Esses resultados foram superiores aos encontrados por DUPAS (2000) que obteve valores para a acurácia geral iguais a 50% e 5,7% e índice κ iguais a 8% e -5%, na classificação de imagens JERS e ERS, respectivamente.

TABELA 8 – MATRIZ DE ERROS DA CLASSIFICAÇÃO SUPERVISIONADA DA IMAGEM JERS1-SAR

DADOS DE REFERÊNCIA ("verdade de campo")						
CLASSES	Solo exposto	Pinus spp	Eucalyptus spp	Mata nativa	Água	Total das linhas
Solo exposto	16	0	4	2	2	24
Pinus spp	12	52	7	25	4	100
Eucalyptus spp	2	3	38	11	0	54
Mata nativa	2	4	4	15	0	25
Água	0	0	0	0	3	3
Total das colunas	32	59	53	53	9	206

Os valores obtidos para a acurácia do produtor revelaram que as áreas de *Pinus spp* e *Eucalyptus spp*, com omissão de 11,86 % e 28,3%, respectivamente, foram classificadas satisfatoriamente pelo algoritmo. No entanto o classificador foi ineficaz para mata nativa (acurácia do produtor igual a 28,30%) e água (acurácia do produtor igual a 33,33%). No que diz respeito à mata nativa, a baixa acurácia é provavelmente devida à grande heterogeneidade observada nessa classe que envolve muitas espécies distintas, o que, por sua vez, determina diferentes graus de densidade e tipo do dossel e, conseqüentemente, diferentes respostas do sinal do radar. Pixels localizados na região limítrofe entre duas classes de cobertura geralmente passam a conter informações referentes às duas classes. Pelo fato de as áreas com mata nativa serem pequenas e bastante fragmentadas, são freqüentemente confundidas com a classe “*Pinus spp*”, que é a classe predominante na área de estudo.

A classe “água” praticamente não ocorre na área de estudo, sendo representada apenas por dois pequenos açudes nas porções centro-oeste e sudeste da Fazenda. Em função disso o número de pontos amostrados (9) foi baixo, o que determinou a geração de resultados não-confiáveis sobre o desempenho do classificador para essa categoria. A classe “solo exposto” também é bastante heterogênea, especialmente por englobar áreas sem vegetação, talhões recém-implantados e alguns trechos de estrada mais largos. A acurácia do produtor para esta classe foi equivalente a 50%.

TABELA 9 – ACURÁCIAS DO PRODUTOR E DO USUÁRIO POR CLASSE

CLASSES	ACURÁCIA DO PRODUTOR	ACURÁCIA DO USUÁRIO
Solo exposto	$16/32 * 100 = 50,00$	$16/24 * 100 = 66,67$
Pinus spp	$52/59 * 100 = 88,14$	$52/100 * 100 = 52,00$
Eucalyptus spp	$38/53 * 100 = 71,70$	$38/54 * 100 = 70,37$
Mata nativa	$15/53 * 100 = 28,30$	$15/25 * 100 = 60,00$
Água	$3/9 * 100 = 33,33$	$3/3 * 100 = 100,00$

A acurácia do usuário deve ser interpretada como a probabilidade de se encontrar, no terreno, a classe que está sendo indicada pelo mapa produzido pela classificação. Embora a acurácia do produtor tenha sido baixa para a classe “água”, a acurácia do usuário revela que 100% da área indicada como “água” no mapa será realmente “água” no terreno. Para a classe “Pinus spp” a acurácia do usuário foi baixa (cerca de 50%), pois muitos dos pontos pertencentes a outras classes acabaram sendo classificados como “Pinus spp” e, portanto, o que se vê no mapa não é o que se encontra realmente no terreno. As acurácias do usuário para as classes restantes apresentaram valores apenas aceitáveis.

O treinamento para a classificação supervisionada empregando-se o algoritmo de *Bhattacharyya* consiste num procedimento iterativo, em que o analista define as amostras de treinamento selecionando, apropriadamente, as regiões correspondentes a cada classe sobre a imagem segmentada. É importante ressaltar que a segmentação prévia, com exaustiva pesquisa dos limiares ótimos para similaridade e área mínima, irá determinar o sucesso da classificação por regiões.

4.1.2.5 Geração do mapa temático

Ao discutirem as reais possibilidades das técnicas de classificações digitais, LINHARES et al. (2000) ponderam que, quando a edição é pequena ou inexistente, a rapidez do classificador torna-se uma evidente vantagem. No entanto, na presente pesquisa, os resultados obtidos com as classificações supervisionada e não-

supervisionada permitiram constatar a necessidade de inúmeras intervenções do analista para que fosse atingida a acuracidade temática desejada no mapa final.

Segundo SOARES (1998), uma classificação de imagens SAR por métodos tradicionais de interpretação visual fornece melhores resultados que os classificadores digitais desenvolvidos para imagens digitais multibandas do espectro óptico. A intervenção humana no processo de definição de classes é a principal característica e vantagem da interpretação visual (LINHARES et al., 2000).

Em função disto optou-se pela geração do mapa temático através do processo de interpretação visual, não na sua abordagem clássica, mas, sim, aproveitando as regiões criadas no processo de segmentação (v. item 4.1.2.1).

Dessa forma o arquivo de linhas correspondente à imagem segmentada foi transformado da categoria “imagem” para categoria “temático” no *software* SPRING, definindo-se quatro classes: *Pinus spp*, *Eucalyptus spp*, solo exposto e mata nativa. Em seguida, utilizando dados auxiliares como fotografias aéreas e mapas do cadastro florestal, foi efetuada a associação das classes temáticas aos respectivos polígonos criados pelo segmentador, de acordo com o procedimento sugerido por NASCIMENTO e ALMEIDA FILHO (1996).

A Figura 25 mostra o mapa temático final, gerado a partir de uma abordagem combinada “segmentação/interpretação visual” da imagem JERS1-SAR. Sem dúvida, pela própria participação do analista, os resultados se aproximam muito mais da verdade de campo do que aqueles gerados pela classificação automática.

Através de análise visual pode-se perceber que, de um modo geral, as categorias foram bem discriminadas, abrangendo os grandes grupos tipológicos existentes na área. Contudo, pequenas áreas fragmentadas, tais como as ocupadas por mata nativa e solo exposto, não conseguiram ser delimitadas pela segmentação e foram incorporadas às classes predominantes adjacentes.

JENSEN (1996) comenta que há, atualmente, uma ressurgência da arte e ciência da fotointerpretação visual, à medida que os sistemas de sensoriamento remoto digitais fornecem imagens de melhor resolução espacial.

Pode-se concluir que na abordagem combinada – na forma como foi aplicada nesta pesquisa – a utilização da técnica de segmentação substituiu várias etapas da interpretação visual, o que pode ser considerado uma vantagem em termos de economia de tempo e de volume de trabalho.

Percebe-se que esses resultados em muito se assemelham àqueles obtidos pela classificação por regiões empregando-se o algoritmo de *Bhattacharyya* (Fig. 24), pois ambos os procedimentos se baseiam nos polígonos gerados pela segmentação e exigem a participação do analista.

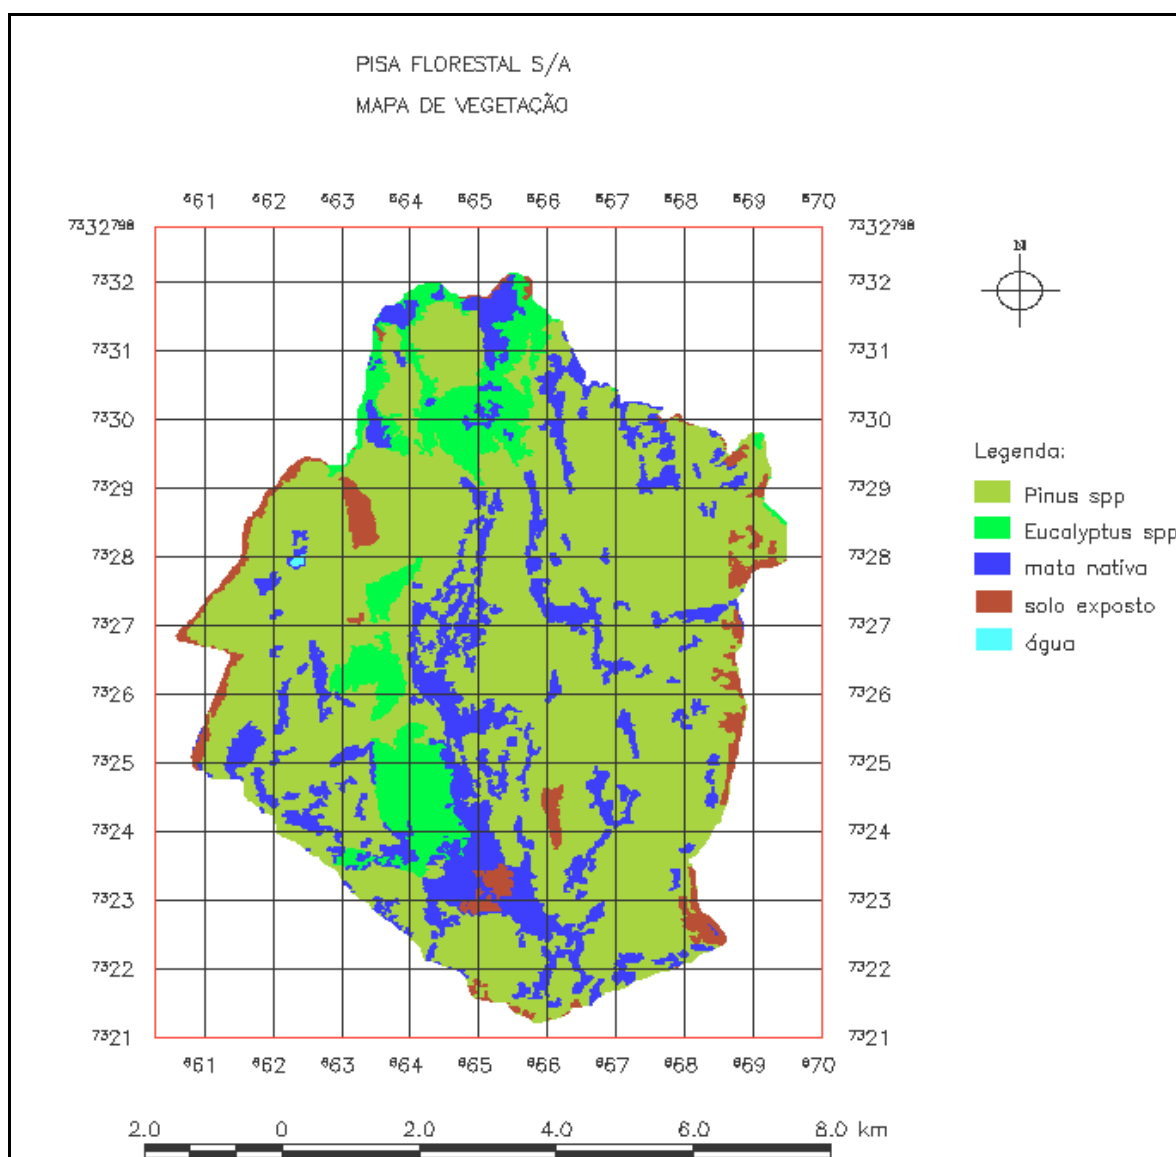


FIGURA 25 – MAPA DE VEGETAÇÃO DA ÁREA DE ESTUDO ELABORADO A PARTIR DE SEGMENTAÇÃO E INTERPRETAÇÃO VISUAL DA IMAGEM JERS1-SAR

4.1.2.6 Estimativa de áreas de talhões

A Figura 26 contem uma composição mostrando, ao fundo, a imagem JERS correspondente à área de estudo e, sobre ela, em cores, os 10 polígonos-amostra vetorizados.




FIGURA 26 – TALHÕES-AMOSTRA VETORIZADOS SOBRE A IMAGEM JERS1-SAR

A maior dificuldade no processo de digitalização consistiu na determinação dos limites dos talhões, uma vez que a geometria de aquisição da imagem (visada lateral) e a altura das árvores fizeram com que muitas das estradas não estivessem visíveis. Além disso, talhões contíguos freqüentemente estavam separados por estradas

estreitas ou simples aceiros, de largura inferior a 18 m, que é a resolução espacial da imagem JERS1-SAR e, portanto, não eram identificáveis.

Na Fazenda Mocambo, cuja divisão dos talhões é bastante regular e cuja malha viária é distribuída segundo um arranjo quadricular, praticamente todas as estradas no sentido leste-oeste tiveram sua identificação prejudicada. SABINS (1997) argumenta que feições lineares, tais como estradas e aceiros, orientadas paralelamente à direção de visada, ficam suprimidas e difíceis de se reconhecer. Já as estradas orientadas no sentido norte-sul, formando, praticamente, um ângulo reto com a iluminação do radar, deveriam produzir o máximo sinal de retorno. No entanto, tal fato não se verificou para os limites de alguns talhões devido à influência da altura das árvores, que mascararam a discriminação das estradas, gerando áreas de sombra.

A discriminação entre talhões contíguos foi bastante dificultada nos casos em que os mesmos eram compostos pela mesma espécie, idade e tratos silviculturais (desbaste), pois nessas circunstâncias o sinal de retorno do radar era idêntico, fornecendo uma mesma resposta em termos de textura e tonalidade.

Os limites da área da Fazenda voltados para a direção de visada do radar foram bem discriminados, enquanto que a identificação dos limites no *far range* ficou prejudicada pela ocorrência de sombras.

Devido a essas dificuldades não foi possível adquirir mais amostras de talhões sobre a imagem JERS, o que seria desejável para se obter estimativas mais precisas do erro amostral.

Talhões de diferentes espécies (*Pinus spp*, *Eucalyptus spp*) e mata nativa localizada no entorno da Fazenda e em áreas de preservação permanente dentro dos projetos puderam ser bem discriminados. No entanto os melhores resultados foram alcançados na separação entre talhões mais velhos e mais densos e áreas de solo exposto ou com florestas jovens, conforme já constatado por AHERN et al. (1993b), LICHTENEGGER (1994) e SCALES et al. (1997).

Comparando-se as áreas constantes do cadastro florestal e aquelas estimadas através da vetorização sobre a imagem JERS ortorretificada concluiu-se que existe diferença estatística significativa entre suas médias, conforme comprovado através da

realização do teste t para amostras emparelhadas. Nesse caso a hipótese nula foi rejeitada, pois o valor de t calculado foi igual a $|-4,10|$, portanto maior que o valor de t tabelado (1,833), para um nível de probabilidade $\alpha = 0,05$ e 9 graus de liberdade.

A maior diferença percentual entre áreas reais e estimadas foi igual a 6,43% para um talhão-amostra de área real igual a 19,27 ha. A menor diferença percentual calculada foi 0,20%, para um talhão de 112,7 ha. A média das diferenças percentuais entre áreas reais e estimadas foi igual a 3,21%. Para a maioria dos polígonos constatou-se que houve superestimativa das áreas vetorizadas sobre a imagem JERS.

Quanto à magnitude das diferenças percentuais observadas, constatou-se que os erros são mais significativos para áreas pequenas. Conseqüentemente houve uma diminuição do erro relativo com o aumento das áreas dos talhões amostrados. Esses mesmos resultados foram observados por SANO et al. (1993) quando quantificaram erros expressos como percentagem da área real de polígonos digitalizados através de mesa digitalizadora.

Também foi vetorizado o perímetro da área de estudo, tendo-se obtido uma diferença percentual igual a 1,49% em relação à área real obtida do cadastro da empresa.

Os erros na estimativa das áreas são mais significativos quando a delimitação dos talhões sofre influência da altura das árvores. Assim, os limites que se situam na porção *far-range* da imagem estão mais sujeitos aos efeitos de sombra de radar.

4.2 IMAGENS LANDSAT-5 TM

4.2.1 Recorte da Imagem

Após o recorte da cena LANDSAT órbita 221, ponto 77, contendo a área de estudo, foi obtida, para cada banda, uma imagem de 405 colunas por 416 linhas.

4.2.2 Correção Atmosférica

Analisando-se os histogramas de frequência e as estatísticas da cena LANDSAT TM, observou-se que, nas bandas TM4, TM5 e TM7, o valor mínimo dos DN's foi igual a zero e esses valores foram encontrados no interior dos corpos d'água delimitados nas imagens. Assim não foi necessário aplicar a correção para os efeitos atmosféricos com base no método do mínimo do histograma. De acordo com ERDAS (1999), a suposição de que os DN's realmente deveriam ser iguais a zero nessas regiões e bandas específicas é muito tênue e estudos mais recentes afirmam que o referido método pode estar contribuindo mais para degradar a imagem do que para melhorá-la.

4.2.3 Correções Geométricas

Empregando-se uma transformação linear (polinomial de 1^o. grau) para efetuar a correção geométrica da imagem LANDSAT-5 TM, obteve-se um RMS máximo por ponto igual a 0,33 pixel e um RMS total de 0,221 pixel para todos os pontos considerados no ajuste, o que equivale a um erro de aproximadamente 6,63 metros no terreno.

Após a aplicação da função de mapeamento, os níveis de cinza da imagem foram reamostrados por interpolação bilinear.

4.2.4 Realce de Contraste

As técnicas de realce aplicadas às bandas da imagem LANDSAT TM permitiram uma melhor discriminação das feições de interesse, particularmente dos diversos tipos florestais encontrados na área de estudo. Na maioria das vezes foram efetuados contrastes interativos, com manipulação do histograma. A opção de transformação mais utilizada foi a raiz quadrada, que segundo SPRING (1998), deve ser empregada quando se deseja realçar as porções mais escuras da imagem. O contraste por transformação no espaço de cores não produziu bons resultados.

Todas as operações de realce de contraste efetuadas nas imagens tiveram por objetivo melhorar as condições de visualização e interpretabilidade das feições de interesse. Proporcionaram, também, a possibilidade de se obter uma imagem mais adequada para a seleção de pontos de controle no georreferenciamento e para a definição de amostras de treinamento na classificação supervisionada. As transformações por componentes principais, bem como a classificação das imagens LANDSAT TM, foram efetuadas considerando-se os DNs obtidos após o processo de reamostragem (georreferenciamento), sem realce de contraste.

4.2.5 Composições Coloridas RGB

Embora existam inúmeras combinações de cores possíveis envolvendo as seis bandas (visível e infravermelho) do sensor TM, um pequeno número delas é conveniente para a maioria das aplicações práticas (SABINS, 1997). Dentre as inúmeras combinações de bandas testadas nos canais RGB, a que mais se destacou foi a combinação 543 (RGB), onde foi possível diferenciar plantios de *Pinus spp* com diferentes densidades. Em áreas desbastadas a influência do solo se fez presente, produzindo diferentes tonalidades. A mata nativa e os talhões de *Eucalyptus spp* apresentaram-se em tons verde-claro, sendo que estes últimos apresentaram tonalidades um pouco mais escuras. Os povoamentos de *Pinus spp*, por outro lado,

mostraram-se em tons verde-escuro, sendo o *Pinus taeda* mais escuro que o *Pinus elliottii*.

Outra composição que proporcionou uma boa discriminação das feições de interesse foi a 457 (RGB), permitindo diferenciar *Eucalyptus spp* de nativas, *Pinus taeda* de *Pinus elliottii* e gramíneas de solo exposto. Nessa composição foram realçados detalhes de talhões pequenos, confirmando, assim, o enunciado por SABINS (1997), que afirma que a combinação 457 (RGB) é a que fornece a melhor resolução espacial.

Deve-se ressaltar que as combinações de cores e, por conseguinte, a interpretabilidade das composições coloridas, dependem significativamente do tipo de realce de contraste aplicado para a visualização em tela.

4.2.6 Transformações de Dados

Nesta pesquisa trabalhou-se com os DNs originais, sem transformá-los para valores de radiância. MATHER (1999) recomenda que, quando as escalas de medição não forem compatíveis, deve-se usar unidades padronizadas de variância, ou seja, a matriz de correlação, para medir o grau de associação estatística entre as bandas espectrais. No entanto, a transformação por componentes principais foi efetuada empregando-se a matriz de variância-covariância pelo fato de que a versão atual do software empregado nesta etapa (SPRING) oferece apenas essa opção.

Na Tabela 10 pode-se observar que todas as seis bandas TM possuem correlações positivas relativamente altas entre si, exceto a banda TM4. A menor correlação foi encontrada entre as bandas TM4 e TM7 ($r=0,49$) e entre as bandas TM4 e TM3 ($r=0,50$). Tais resultados são similares aos apresentados em JENSEN (1996), MATHER (1999) e OLIVEIRA (1999), em estudos onde a banda TM4 foi a menos correlacionada com as demais.

TABELA 10 – MATRIZ DE CORRELAÇÃO DAS SEIS BANDAS TM

BANDAS	1	2	3	4	5	7
1	1,00	0,95	0,92	0,52	0,83	0,83
2	0,95	1,00	0,96	0,59	0,92	0,91
3	0,92	0,96	1,00	0,50	0,93	0,96
4	0,52	0,59	0,50	1,00	0,60	0,49
5	0,83	0,92	0,93	0,60	1,00	0,97
7	0,83	0,91	0,96	0,49	0,97	1,00

Os coeficientes das seis componentes principais padrão encontram-se relacionados na Tabela 11, bem como os respectivos auto-valores e a percentagem de variabilidade dos dados concentrada em cada componente. Cerca de 85% da informação das seis bandas está contida na primeira componente (CPa1). As primeiras três componentes (CPa1, CPa2 e CPa3) representam, sozinhas, quase que a totalidade da variância dos dados (98,74 %). Para a CPa1, as bandas 5, 2 e 7 são as que estão contribuindo com mais informação, o que pode ser constatado pela observação dos valores dos carregamentos ou coeficientes, iguais a 0,46; 0,43 e 0,43, respectivamente. Segundo SPRING (1998), a primeira componente contém a informação de brilho associada às sombras da topografia e às grandes variações da reflectância espectral geral das bandas.

TABELA 11 – COEFICIENTES DAS VARIÁVEIS DAS COMPONENTES PRINCIPAIS (MATRIZ DOS AUTO-VETORES TRANSPOSTOS) E AUTO-VALORES, COM BASE NA MATRIZ DE COVARIÂNCIA (BANDAS 1,2,3,4,5 E 7)

CP's	BANDAS						Auto-Valores	% Variância	% Var. Acumulada
	1	2	3	4	5	7			
CPa1	0,40	0,43	0,42	0,26	0,46	0,43	24507,83	85,06	85,06
CPa2	-0,10	-0,04	-0,21	0,95	-0,02	-0,21	2786,74	9,67	94,73
CPa3	-0,70	-0,27	-0,05	0,01	0,49	0,44	1154,16	4,01	98,74
CPa4	-0,46	0,21	0,67	0,11	-0,53	0,06	185,62	0,64	99,38
CPa5	0,36	-0,73	0,18	0,14	-0,29	0,45	131,28	0,46	99,84
CPa6	-0,04	0,40	-0,54	0,02	-0,43	0,61	46,76	0,16	100,00

Embora a segunda componente principal (CPa2) represente apenas 9,67% da variabilidade dos dados, a imagem correspondente (Fig. 27) mostrou-se potencialmente importante para a diferenciação das tipologias existentes na área. Os povoamentos de *Eucalyptus spp* (2) apresentaram-se em tonalidades cinza, diferenciando-se da mata nativa (1), que assumiu tons mais claros, quase brancos. As áreas de solo exposto (3) e a água (4) apareceram em tons pretos, enquanto que tons cinza claro foram observados em áreas de *Pinus spp* (5). A CPa2 apresentou carregamento positivo no canal infravermelho e carregamento negativo na banda visível TM3. Isso significa que o padrão verde foi realçado nessa componente, conforme se pode observar em relação às folhosas, representadas pela mata nativa e pelos povoamentos de *Eucalyptus spp*, que apresentaram os níveis de cinza mais altos da imagem, gerando tonalidades próximas ao branco.




FIGURA 27 – SEGUNDA COMPONENTE PRINCIPAL (CPa2) DAS BANDAS LANDSAT TM 1-5 E 7

As componentes principais selecionadas (CPb e CPc), cujos coeficientes são apresentados nas Tabelas 12 e 13, respectivamente, não acrescentaram novas informações que pudessem ser úteis na discriminação dos alvos de interesse nessa etapa do processamento.

TABELA 12 – COEFICIENTES DAS VARIÁVEIS DAS COMPONENTES PRINCIPAIS (MATRIZ DOS AUTO-VETORES TRANSPOSTOS) E AUTO-VALORES, COM BASE NA MATRIZ DE COVARIÂNCIA (BANDAS 3, 4 E 5)

CP's	BANDAS			Auto-Valores	% Variância	% Var. Acumulada
	3	4	5			
CPb1	0,59	0,44	0,67	11610,47	80,65	80,65
CPb2	-0,39	0,89	-0,23	2470,28	17,16	97,81
CPb3	0,70	0,13	-0,70	316,04	2,20	100,00

TABELA 13 – COEFICIENTES DAS VARIÁVEIS DAS COMPONENTES PRINCIPAIS (MATRIZ DOS AUTO-VETORES TRANSPOSTOS) E AUTO-VALORES, COM BASE NA MATRIZ DE COVARIÂNCIA (BANDAS 4, 5 E 7)

CP's	BANDAS			Auto-Valores	% Variância	% Var. Acumulada
	4	5	7			
CPc1	0,42	0,67	0,61	12090,68	81,98	81,98
CPc2	0,90	-0,21	-0,39	2559,23	17,35	99,33
CPc3	0,13	-0,71	-0,69	99,21	0,67	100,00

Outro tipo de transformação aplicada à imagem LANDSAT foi a razão de bandas, especificamente para a geração do Índice de Vegetação da Diferença Normalizada (NDVI), que produziu uma imagem bastante similar à da componente CPa2, uma vez que o Índice envolve bandas do visível e do infravermelho.

4.2.7 Segmentação de Imagens

Com o intuito de separar a imagem LANDSAT em regiões espectralmente homogêneas, procedeu-se à segmentação conforme o algoritmo de crescimento de regiões, implementado no *software* SPRING. Para tanto foram utilizadas as bandas originais e transformadas que, por análise visual, proporcionaram a melhor

separabilidade entre as classes de interesse. Incluíram-se, então, as bandas TM4, TM5 e TM7, bem como a imagem-razão (NDVI) e a segunda componente principal (CPa2).

A pesquisa dos limiares ótimos para similaridade e área mínima revelou que a melhor combinação envolveu os valores de 43 e 15, respectivamente. A existência de áreas bastante fragmentadas, principalmente na classe “mata nativa”, fez com que o limiar de área mínima tivesse que ser gradativamente reduzido até que regiões tão pequenas quanto 1,35 ha (15 pixels) pudessem ser delimitadas.

As regiões discriminadas através de segmentação puderam ser facilmente associadas às classes temáticas efetivamente existentes na área de estudo. Diminuindo-se o limiar de similaridade para 30, observou-se que o algoritmo foi capaz de discriminar talhões de *Pinus spp* de diferentes espécies. No entanto, ao mesmo tempo, provocou o efeito indesejável de criar pequenos polígonos no interior das classes homogêneas de maiores dimensões.

A imagem segmentada serviu de base aos procedimentos subseqüentes de classificação temática.

4.2.8 Classificação Temática

4.2.8.1 Classificação não-supervisionada

Dentre os três algoritmos testados (um por região – Iseseg; dois por pixel – Isodata e K-médias), nenhum obteve desempenho satisfatório. Esperava-se que o classificador Iseseg, por considerar as regiões criadas pela segmentação, produzisse bons resultados. No entanto, foi criado um número excessivo de classes (15), que, mesmo quando submetidas a um processo de agrupamento durante a edição, não puderam ser associadas às classes existentes na área.

Na classificação por pixel os talhões de *Eucalyptus spp* foram confundidos com mata nativa e *Pinus spp*. A única classe bem delimitada foi “solo exposto”, especialmente com o algoritmo Isodata, que permitiu o delineamento do traçado das estradas mais largas.

4.2.8.2 Classificação supervisionada

Em geral os classificadores por pixel (distância mínima, máxima verossimilhança e ICM) geraram imagens onde as classes temáticas foram confundidas entre si, como, por exemplo, “mata nativa” e “Eucalyptus spp”, “solo exposto” e “água”, etc.

Sem dúvida o melhor algoritmo de classificação supervisionada foi o de *Bhattacharyya*, em que as amostras de treinamento são definidas sobre as regiões previamente criadas pela segmentação. Em função disso, os resultados da classificação, submetidos a um processo mínimo de edição, foram empregados para gerar o mapa de vegetação da área de estudo (Fig. 28).

As imagens efetivamente utilizadas na classificação incluíram as bandas TM4, TM5 e TM7, além da imagem-razão (NDVI) e da CPa2.

Embora apresentando um pouco de confusão com “Eucalyptus spp”, em geral os fragmentos de “mata nativa” foram bem delimitados. Verificou-se, no cadastro florestal, que algumas das áreas classificadas como “solo exposto”, correspondiam, na verdade, a talhões recém-cortados, onde a galhada ainda não havia sido removida ou enleirada. Dessa forma, sua inclusão nessa classe justificou-se pela maior proporção de solo exposto em relação aos outros talhões de *Pinus spp*.

4.2.8.3 Acurácia temática

A acurácia geral da imagem LANDSAT classificada empregando-se o algoritmo de *Bhattacharyya* foi igual a 73,30%, um valor próximo ao que tem sido encontrado em outros estudos envolvendo classificações temáticas de áreas com reflorestamentos (COLEMAN et al., 1990; LINGNAU e ANTUNES, 1999).

Na Tabela 14 é apresentada a matriz de erros da classificação, calculada com base no número de concordâncias e não-concordâncias de 206 pontos de referência, cuja localização exata foi obtida a partir do mapa georreferenciado dos talhões, disponível em meio digital (v. item 4.1.2.4). A partir da matriz de erros calculou-se o Índice κ , que representa o quanto a classificação efetuada foi melhor do que uma

atribuição aleatória de pixels às classes. No presente estudo esse índice foi igual a 0,6457.

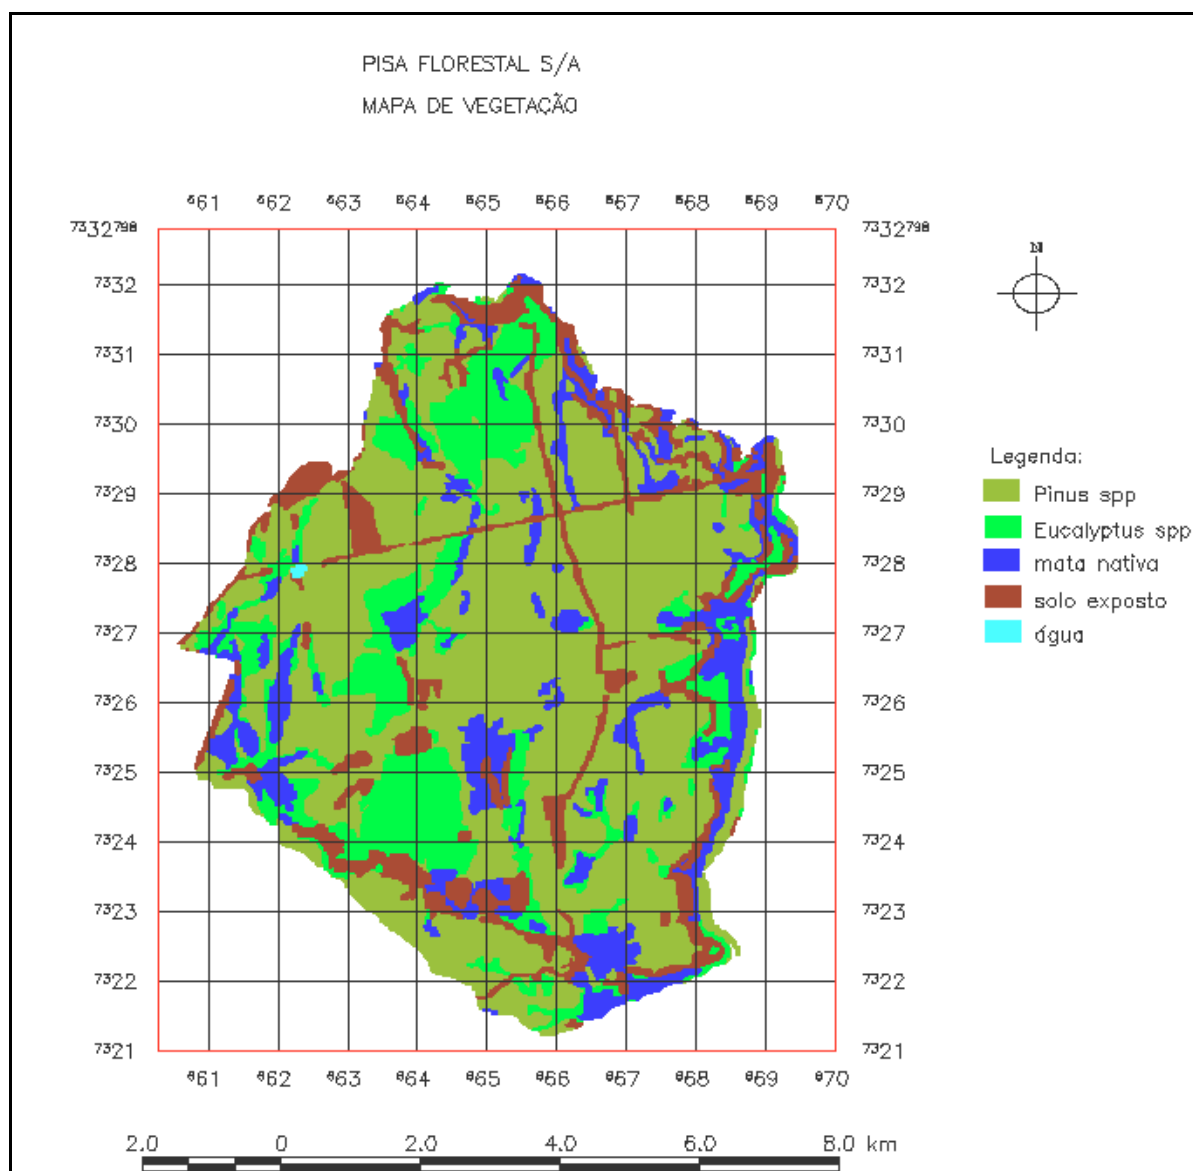


FIGURA 28 – MAPA DE VEGETAÇÃO DA ÁREA DE ESTUDO ELABORADO A PARTIR DE CLASSIFICAÇÃO SUPERVISIONADA DA IMAGEM LANDSAT-5 TM

TABELA 14 – MATRIZ DE ERROS DA CLASSIFICAÇÃO SUPERVISIONADA DA IMAGEM LANDSAT-5 TM

DADOS DE REFERÊNCIA ("verdade de campo")						
CLASSES	Solo exposto	Pinus spp	Eucalyptus spp	Mata nativa	Água	Total das linhas
Solo exposto	20	1	1	6	0	28
Pinus spp	10	50	1	11	1	73
Eucalyptus spp	1	7	47	8	2	65
Mata nativa	0	1	4	28	0	33
Água	1	0	0	0	6	7
Total das colunas	32	59	53	53	9	206

Mais informativas, no entanto, são as acurácias do produtor e do usuário, apresentadas na Tabela 15, uma vez que envolvem todos os valores relacionados na matriz de erros. A classe “Eucalyptus spp” foi a que apresentou a maior acurácia do produtor (88,68%), ficando a classe “Pinus spp” em segundo lugar, com 84,75%. Dos 53 pontos de referência coletados nas áreas correspondentes a “mata nativa”, o classificador foi eficiente apenas em 52,83% dos casos.

A interpretação dos resultados encontrados para as acurácias do usuário revelam, no entanto, que 84,85 % das áreas indicadas como “mata nativa” no mapa gerado pela classificação, efetivamente correspondem a essa classe no terreno, o mesmo ocorrendo com a classe “água” (85,71%). Já a classe “Pinus spp” apresentou baixa acurácia do usuário (68,49%), também em função da migração de alguns pontos de “solo exposto” e “mata nativa” para essa classe.

TABELA 15 – ACURÁCIAS DO PRODUTOR E DO USUÁRIO POR CLASSE

CLASSES	ACURÁCIA DO PRODUTOR	ACURÁCIA DO USUÁRIO
Solo exposto	$20/32 * 100 = 62,50$	$20/28 * 100 = 71,43$
Pinus spp	$50/59 * 100 = 84,75$	$50/73 * 100 = 68,49$
Eucalyptus spp	$47/53 * 100 = 88,68$	$47/65 * 100 = 72,31$
Mata nativa	$28/53 * 100 = 52,83$	$28/33 * 100 = 84,85$
Água	$6/9 * 100 = 66,67$	$6/7 * 100 = 85,71$

4.3 FUSÃO DE IMAGENS LANDSAT- 5 TM E JERS1-SAR

4.3.1 Registro de Imagens

Para efetuar o registro entre a imagem LANDSAT e a imagem JERS foram selecionados 12 pontos de controle, cujos respectivos erros em x e y , bem como o RMS por ponto, encontram-se listados no Apêndice 1. O RMS médio foi de 0,43 pixels, o que equivale a um erro de aproximadamente 8 metros no terreno.

Por ocasião dos procedimentos de registro, o tamanho do pixel da imagem LANDSAT (30 m) foi automaticamente reamostrado para a resolução espacial da imagem JERS (18 m). Foi necessário, também, efetuar um recorte na imagem LANDSAT após o registro, para fazê-la coincidir pixel a pixel e em tamanho com a imagem JERS. Dessa forma obteve-se um arquivo contendo as seis bandas TM e a imagem JERS, com dimensões de 559 colunas por 657 linhas.

4.3.2 Técnicas de Fusão de Imagens

4.3.2.1 Combinação simples de bandas

Observando-se as inúmeras combinações simples de bandas, testadas nos canais RGB, constatou-se que a atribuição da imagem JERS ao canal verde (G) produz resultados sistematicamente insatisfatórios. As imagens geradas apresentaram influência do *speckle* e foram, sem dúvida nenhuma, dominadas pela radiometria da imagem JERS. A contribuição multiespectral da imagem LANDSAT foi neutralizada, prejudicando, assim, a discriminação das diferentes classes temáticas existentes na área.

As melhores composições foram aquelas em que se utilizou a banda do radar nos canais vermelho (R) ou azul (B), confirmando os resultados encontrados por SILVA JR. (1999). Segundo esse mesmo autor, tal fato se deve, em parte, à maior sensibilidade do olho humano para esses comprimentos de onda.

Selecionou-se a composição TM5-TM4-JERS (RGB), apresentada na Figura 29, como a combinação de bandas que melhor caracterizou as classes de vegetação, possibilitando a separação entre mata nativa e *Eucalyptus spp* para a maioria das áreas em que essas formações aparecem. As classes “solo exposto” e “áreas de corte recente” foram bem discriminadas, apresentando tonalidades carmim e rosa, respectivamente. Entretanto, áreas com gramíneas, conforme as que aparecem na porção leste da imagem, foram confundidas com “áreas de corte recente”.

Embora a qualidade da figura impressa torne difícil a percepção de diferentes tonalidades de azul, a análise dessa composição no monitor permitiu separar a classe “Pinus” em duas categorias distintas: povoamentos jovens (1) e povoamentos maduros (2).

Através da combinação de bandas em composição colorida pôde-se observar, também, que as imagens dos dois sensores estão perfeitamente sobrepostas, sem deslocamentos aparentes, principalmente nas estradas e limites de talhões. Isso vem comprovar que o resultado do registro entre imagens foi satisfatório, estando condicionado à precisão do ajuste da função polinomial (georreferenciamento da imagem LANDSAT) e do ajuste do modelo do satélite (ortorretificação da imagem JERS).

4.3.2.2 Componentes principais

A Tabela 16 mostra os diferentes conjuntos de dados submetidos a transformações estatísticas por componentes principais. Numa primeira abordagem considerou-se apenas as bandas LANDSAT TM. Assim, a técnica de fusão consistiu na atribuição das CPs a dois dos canais RGB disponíveis, enquanto que a banda JERS foi atribuída ao canal restante.

Os auto-valores e auto-vetores das seis componentes principais padrão (Cpa), bem como das componentes principais selecionadas (CPb e CPC) são apresentados nas Tabelas 11, 12 e 13, respectivamente, no item 4.2.6, que trata do processamento das imagens LANDSAT.

Numa segunda abordagem incluiu-se, também, a imagem JERS no conjunto de dados submetidos à transformação estatística por componentes principais. As CP's resultantes foram, então, utilizadas em composições coloridas RGB.




FIGURA 29 – COMPOSIÇÃO COLORIDA EM RGB (R-TM5; G-TM4; B-JERS)

As melhores combinações das componentes principais e da imagem JERS foram aquelas em que se atribuiu a imagem de radar ao canal azul (B) ou vermelho

(R). Embora as CPa1 e CPa2 juntas representassem 94,73% da variância dos dados, sua inclusão na composição colorida gerou imagens em que não foi possível diferenciar as classes “Eucalyptus spp” e “mata nativa”. O mesmo ocorreu empregando-se as CPb1 e CPb2 (componentes principais seletivas TM3, TM4, TM5), que, juntas, representam 97,81% da variância acumulada. No entanto, ambas as composições foram as que proporcionaram as melhores resoluções espaciais, permitindo, inclusive, a detecção de estradas no interior dos talhões.

TABELA 16 – SENSORES E BANDAS ENVOLVIDOS NA TRANSFORMAÇÃO POR COMPONENTES PRINCIPAIS PARA A FUSÃO DE DADOS ÓPTICOS E DE RADAR

Apenas bandas LANDSAT TM	Componentes principais
Padrão (a) – TM1, TM2, TM3, TM4, TM5, TM7	CPa1, CPa2, CPa3, CPa4, CPa5, CPa6
Selecionadas (b) – TM3, TM4, TM5	CPb1, CPb2, CPb3
Selecionadas (c) – TM4, TM5, TM7	CPc1, CPc2, CPc3
Bandas LANDSAT TM e JERS	Componentes principais
Padrão (d) – TM1, TM2, TM3, TM4, TM5, TM7, JERS	CPd1, CPd2, CPd3, CPd4, CPd5, CPd6, CPd7
Selecionadas (e) – TM3, TM4, TM5, JERS	CPe1, CPe2, CPe3, CPe4
Selecionadas (f) – TM4, TM5, TM7, JERS	CPf1, CPf2, CPf3, CPf4

Após inúmeros testes envolvendo todas as componentes principais, selecionou-se a composição CPa5-CPa2-JERS (RGB) como a combinação de bandas que melhor discriminou as classes de interesse. Embora a CPa2 e a CPa5 representem, respectivamente, apenas 9,67% e 0,46% da variância dos dados, a sua combinação com a imagem JERS, mostrada na Figura 30, permitiu separar bem as classes “Eucalyptus spp”, que aparece em amarelo, e “mata nativa”, em verde. Também pôde-se diferenciar “Pinus spp (jovem)” e “Pinus spp (maduro)”, assim como “solo exposto” e “áreas de corte recente”. Conforme já se ressaltou no item 4.2.6, a CPa2 é, caracteristicamente, a componente “vegetação”, uma vez que é maciçamente dominada pela banda TM 4 (infravermelho próximo) e apresenta carregamentos negativos e baixos nas bandas do visível. Por outro lado a CPa5 apresentou o maior

coeficiente na banda TM 2, que corresponde aproximadamente à região verde do espectro e é, portanto, uma região importante para a detecção da vegetação verde sadia.




FIGURA 30 – COMPOSIÇÃO COLORIDA DA IMAGEM JERS E DAS COMPONENTES PRINCIPAIS DE TODAS AS BANDAS LANDSAT TM (**R**-CPa5; **G**-CPa2; **B**-JERS).

Pode-se observar, a partir da Tabela 17, que os DNs da imagem JERS apresentam correlação baixa (inferior a 0,6) e negativa com as bandas do sensor LANDSAT TM. Isso comprova que a técnica de fusão dessas imagens pode oferecer ganhos significativos, uma vez que a falta de correlação indica que novas informações são acrescentadas por um e por outro sensor quando da sua integração.

TABELA 17 – MATRIZ DE CORRELAÇÃO ENTRE AS SEIS BANDAS TM E JERS

BANDAS	JERS
TM1	-0,41
TM2	-0,49
TM3	-0,47
TM4	-0,34
TM5	-0,54
TM7	-0,49
JERS	1,00

Na fase do processamento das componentes principais que incluíram as bandas LANDSAT TM e a imagem JERS empregou-se a matriz de correlação, dada a natureza completamente diversa das duas imagens, tanto em termos de geometria de aquisição quanto dos fatores que determinam a resposta dos alvos para cada um dos sensores. Quando se utiliza a matriz de correlação na transformação por componentes principais, a proporção da variância dos dados (padronizada) devida à k -ésima CP é igual ao k -ésimo auto-valor dividido pelo número de CP's (MARDIA et al., 1979), que, por sua vez, é igual ao número de bandas envolvidas no processo.

As Tabelas 18 a 20 referem-se aos parâmetros das componentes principais CPd, CPe e CPf, respectivamente. Os cálculos foram efetuados empregando-se o *software* ENVI, que oferece a opção da utilização da matriz de correlação ou da matriz de covariância.

TABELA 18 – COEFICIENTES DAS VARIÁVEIS DAS COMPONENTES PRINCIPAIS (MATRIZ DOS AUTO-VETORES TRANSPOSTOS) E AUTO-VALORES, COM BASE NA MATRIZ DE CORRELAÇÃO (BANDAS TM 1,2,3,4,5,7 E JERS).

CP's	BANDAS							Auto-Valores	% Variância	% Var. Acum.
	1	2	3	4	5	7	JERS			
CPd1	-0,39	-0,43	-0,42	-0,27	-0,42	-0,41	0,26	5,241542	74,88	74,88
CPd2	-0,23	-0,14	-0,24	0,46	-0,03	-0,16	-0,79	0,730812	10,44	85,32
CPd3	0,04	0,03	-0,11	0,83	-0,03	-0,14	0,53	0,671077	9,59	94,91
CPd4	0,68	0,22	0,02	-0,04	-0,48	-0,48	-0,16	0,291995	4,17	99,08
CPd5	0,57	-0,51	-0,52	-0,03	0,33	0,20	0,01	0,035605	0,51	99,59
CPd6	0,09	-0,61	0,53	0,15	-0,46	0,33	-0,04	0,019452	0,28	99,87
CPd7	-0,02	0,35	-0,46	0,03	-0,52	0,63	-0,01	0,009457	0,13	100,00

TABELA 19 – COEFICIENTES DAS VARIÁVEIS DAS COMPONENTES PRINCIPAIS (MATRIZ DOS AUTO-VETORES TRANSPOSTOS) E AUTO-VALORES, COM BASE NA MATRIZ DE CORRELAÇÃO (BANDAS TM 3,4,5 E JERS).

CP's	BANDAS				Auto-Valores	% Variância	% Var. Acumulada
	3	4	5	JERS			
CPe1	-0,55	-0,43	-0,58	0,42	2,691903	67,30	67,30
CPe2	-0,00	0,67	0,04	0,74	0,663975	16,60	83,90
CPe3	-0,52	0,59	-0,32	-0,52	0,578268	14,46	98,36
CPe4	0,65	0,11	-0,75	-0,06	0,065854	1,64	100,00

TABELA 20 – COEFICIENTES DAS VARIÁVEIS DAS COMPONENTES PRINCIPAIS (MATRIZ DOS AUTO-VETORES TRANSPOSTOS) E AUTO-VALORES, COM BASE NA MATRIZ DE CORRELAÇÃO (BANDAS TM 4,5,7 E JERS).

CP's	BANDAS				Auto-Valores	% Variância	% Var. Acumulada
	4	5	7	JERS			
CPf1	-0,42	-0,58	-0,56	0,42	2,734833	68,37	68,37
CPf2	-0,73	-0,02	0,07	-0,68	0,665121	16,63	85,00
CPf3	-0,53	0,34	0,49	0,60	0,586455	14,66	99,66
CPf4	0,11	-0,74	0,66	-0,03	0,013592	0,34	100,00

Em geral os resultados obtidos com a inclusão da imagem JERS no conjunto de dados submetidos a transformações estatísticas por componentes principais não foram satisfatórios. As imagens geradas foram, na sua maioria, influenciadas pela radiometria do radar, e, conseqüentemente, pelo *speckle*. Foram testadas em

composições coloridas RGB todas as combinações de CPs que, numa análise individual, permitissem a discriminação das classes existentes. Empregou-se tanto as CPs padrão como as selecionadas.

Embora a qualidade dessas composições não seja tão boa quanto a apresentada pelas CP's que incluíram apenas as bandas TM, selecionou-se a composição CPf1-CPf4-CPf3 (RGB), apresentada na Figura 31.




FIGURA 31 – COMPOSIÇÃO COLORIDA DAS COMPONENTES PRINCIPAIS INCLUINDO AS BANDAS LANDSAT TM4, TM5, TM7 E JERS (R-CPf1; G-CPf4; B-CPf3).

Nessa Figura destaca-se a boa capacidade de discriminação entre *Pinus elliottii* e *Pinus taeda* (talhões indicados pelas setas) após o 2º. desbaste. Tal separação não havia sido observada com tanta nitidez em nenhuma das composições testadas anteriormente.

4.3.2.3 Transformação IHS

Os produtos híbridos “LANDSAT-5 TM – JERS1-SAR” obtidos pela transformação IHS apresentaram, em geral, qualidade inferior àqueles gerados pela combinação simples de bandas ou de componentes principais. Foram testadas as substituições dos canais “Intensidade (I)” e “Matiz (H)”, separadamente, pela imagem JERS e várias composições coloridas dos dados retransformados para o espaço RGB.

As Figuras 32 e 33 mostram detalhes ampliados da área de estudo, em imagens obtidas por transformação IHS, nas quais se substituiu o canal “Intensidade” pela imagem JERS. Embora a separabilidade entre classes tenha sido insatisfatória considerando a Fazenda no seu todo, algumas categorias conseguiram ser bem discriminadas nesses produtos híbridos. É o caso, por exemplo, dos talhões de *Eucalyptus spp* (1), mata nativa (2) e gramíneas (3), observáveis na Figura 32, sendo que até então a classe “gramíneas” não havia sido diferenciada de “mata nativa” ou “solo exposto”.




FIGURA 32 – INTEGRAÇÃO DAS COMPONENTES PRINCIPAIS (CPb1, CPb2, CPb3) LANDSAT TM E JERS POR TRANSFORMAÇÃO IHS (DETALHE DA ÁREA DE ESTUDO)

Os talhões de *Pinus taeda* 3^o. desbaste (1), que aparecem na porção superior da Figura 33 (a), apenas conseguiram ser discriminados na imagem híbrida em que uma composição colorida LANDSAT TM (R-3,G-4,B-5) foi transformada para o espaço IHS e, em seguida, sofreu transformação inversa, sendo o canal “Intensidade” substituído pela imagem JERS. Na porção inferior da mesma imagem observa-se um talhão de *Pinus oocarpa* 3^o. desbaste (2), que, em outras composições não foi tão bem delimitado. Na Figura 33 (b), que mostra outra região da mesma imagem, aparecem os talhões de *Pinus taeda* 2^o. desbaste que já haviam sido detectados na composição colorida das componentes principais incluindo bandas TM e imagem JERS.




FIGURA 33 – INTEGRAÇÃO DE IMAGENS LANDSAT TM (BANDAS TM3, TM4, TM5) E JERS POR TRANSFORMAÇÃO IHS (a, b - DETALHES DA ÁREA DE ESTUDO)

Outra transformação testada foi aquela em que, partindo-se de uma composição original TM 5 (R), CPa2 (G), NDVI (B), efetuou-se a transformação para o espaço IHS e, na transformação inversa, substituiu-se o canal “Matiz (H)” pela imagem JERS. A Figura 34 mostra um detalhe ampliado da área de estudo numa composição colorida em que se atribuiu a banda retransformada da TM5 ao canal vermelho (R), a imagem JERS ao canal verde (G) e a banda retransformada do NDVI ao canal azul (B). As áreas (1), (2) e (3) mostram talhões cortados em diferentes épocas. No talhão cortado há mais tempo (1) os tons amarelo são indicativos de resíduos da exploração que já perderam sua coloração verde natural. Na área (2),

cortada há menos tempo, as acículas já sofreram mudança parcial de coloração. Na área cortada mais recentemente (3), as acículas mantêm um tom verde similar aos talhões de *Pinus spp* nessa mesma idade que ainda não foram cortados. Tal fato evidencia a sensibilidade desse produto híbrido para a detecção de mudanças de coloração para a galhada que permanece no solo após o corte.

Outro detalhe observado nessa composição é a discriminação de áreas com *Pinus serotina* que, na Figura 34, aparecem em tons mais escuros (4). O plantio foi efetuado em caráter experimental, com o intuito de proteger os cursos d'água, anteriormente desprovidos de vegetação em suas margens.




FIGURA 34 – INTEGRAÇÃO DE IMAGENS LANDSAT (TM5, CPa2, NDVI) E JERS POR TRANSFORMAÇÃO IHS. DETALHE AMPLIADO DA ÁREA DE ESTUDO

Considerando que não existem, em princípio, critérios rígidos e previamente definidos para as opções de substituição dos canais IHS (CARVALHO, 1997), procurou-se testar alguns dos procedimentos alternativos sugeridos na literatura. Partindo-se de uma composição colorida das bandas LANDSAT TM 5 (R), TM4 (G) e TM3 (B), efetuou-se a transformação para os canais IHS e, na transformação inversa, o canal “Intensidade (I)” foi substituído pela imagem JERS e o canal “Matiz (H)” foi substituído pelo canal “Intensidade (I)”, num procedimento análogo ao adotado por AMARAL et al. (1997) na fusão de imagens LANDSAT TM e RADARSAT. As Figuras 35 (a) e 35 (b) mostram o produto híbrido resultante dessa transformação, em detalhes da área de estudo correspondentes aos mesmos locais apresentados nas Figuras 33 (a) e 33 (b). Na Figura 35 (a) nota-se, além dos talhões de *Pinus taeda* 3°.

desbaste (1), uma pequena clareira (2) no interior de um talhão, que não havia sido detectada em outras imagens e que, provavelmente, corresponde a uma área de solo exposto com gramíneas ou vegetação rasteira. As setas da Figura 35 (b) indicam os talhões de *Pinus taeda* 2º. desbaste que, nessa imagem, foram bem delimitados.




FIGURA 35 – INTEGRAÇÃO DE IMAGENS LANDSAT TM (BANDAS TM3, TM4, TM5) E JERS POR TRANSFORMAÇÃO IHS, DESCARTANDO-SE O CANAL “MATIZ (H)”. (a, b - DETALHES DA ÁREA DE ESTUDO).

Ainda um detalhe do mesmo produto híbrido, correspondente à porção oeste da Fazenda Mocambo, é mostrado na Figura 36. Observa-se que um talhão de *Eucalyptus spp* (1) foi confundido com “mata nativa” (2) e a área em verde (3) confundiu-se com a classe “Eucalyptus spp” (4). De acordo com dados do cadastro florestal trata-se de um talhão de *Pinus taeda* maduro, com grande percentual de mistura de espécies nativas regeneradas e em fase de exploração na data de aquisição das imagens.




FIGURA 36 – INTEGRAÇÃO DE IMAGENS LANDSAT TM (BANDAS TM3, TM4, TM5) E JERS POR TRANSFORMAÇÃO IHS, DESCARTANDO-SE O CANAL “MATIZ (H)”.DETALHE DA ÁREA DE ESTUDO

DAMIÃO (1994) aplicou a transformação IHS a partir de uma composição colorida que incluía a banda LANDSAT TM 4 no canal R, a primeira componente principal do conjunto de todas as bandas LANDSAT mais a imagem JERS no canal G e a imagem JERS original no canal B. As imagens “Intensidade (I)”, “Matiz (H)” e “Saturação (S)” resultantes foram, então, submetidas a um realce de contraste e depois foram retransformadas para o espaço RGB. Adotando-se procedimento similar, obteve-se a imagem híbrida mostrada na Figura 37.

Na Figura 37 o primeiro aspecto a ser ressaltado é que o produto híbrido incorporou a informação de relevo – característica de imagens SAR – e a informação multiespectral, oriunda das imagens LANDSAT TM. Tal associação pode ser vantajosa no caso da interpretação visual de imagens, uma vez que se pode inferir novas informações a respeito da cobertura do solo em função da rede de drenagem e da resposta espectral e dos níveis de brilho nos aclives e declives do terreno. Nota-se, também, que houve boa definição dos limites dos polígonos correspondentes às

diferentes feições existentes na área. Esse produto híbrido, no entanto, não foi satisfatório quanto à delimitação de estradas, com exceção de uma estrada e de um aceiro com dimensões maiores que cortam a Fazenda no sentido norte-sul e leste-oeste, respectivamente.




FIGURA 37 – COMPOSIÇÃO COLORIDA RESULTANTE DA TRANSFORMAÇÃO IHS (**R**-RETRANSFORMADA DA TM4, **G**-RETRANSFORMADA DA JERS, **B**-RETRANSFORMADA DA PCd1)

Quanto às categorias temáticas, pode-se afirmar que houve discriminação de talhões de *Pinus spp* de diferentes densidades, que estão associadas à idade e aos tratamentos silviculturais (desbastes). Os povoamentos que se encontram no 3º. desbaste apresentam menor densidade de copas, o que faz com que a resposta espectral seja influenciada, também, pela camada que recobre o solo, ou seja, acículas mortas e demais material orgânico em decomposição. Além disso observa-se que outros talhões na porção leste da Fazenda, caracterizados como “*Pinus spp* (desbaste)” na Figura 37, também apresentam resposta espectral influenciada pelo solo. No entanto, nesse caso específico, trata-se de um enleiramento da vegetação nativa por ocasião do plantio.

A classe “solo exposto” foi detectada tanto em talhões com plantios novos, como nas estradas e aceiros da Fazenda. A classe “corte recente” apresentou-se em tonalidade mais clara do que “solo exposto” e corresponde a áreas submetidas a corte e onde a camada de biomassa encontra-se recobrindo o solo. Em geral houve boa discriminação entre “mata nativa” e “*Eucalyptus spp*”, principalmente em áreas onde essas classes são contíguas.

4.3.3 Segmentação de Imagens

Dentre todos os produtos da integração de dados “LANDSAT-5 TM / JERS1-SAR”, a composição colorida formada pelas componentes principais CPa5 e CPa2 nos canais vermelho e verde, respectivamente, e a imagem JERS no canal azul, foi considerada como a que melhor discriminou as classes existentes na área. Em função disso, a classificação temática foi efetuada sobre esse produto.

Com base na experiência adquirida nas etapas anteriores, optou-se por utilizar o algoritmo *Bhattacharyya*, de classificação supervisionada por regiões, que foi o mais eficiente para cada sensor separadamente. A composição colorida (Fig. 30) foi, então, submetida ao processo de segmentação de imagens, visando gerar regiões espectralmente homogêneas, utilizadas como áreas de treinamento do classificador.

Foram testadas inúmeras combinações de valores para os limiares de similaridade e área mínima, desde 20-30 a 50-50. O limiar de similaridade igual a 20

proporcionou a criação de um número excessivo de regiões, enquanto que o limiar de 50 fez com que algumas tipologias deixassem de ser delimitadas. Os valores para área mínima podem ser estimados *a priori*, se houver um conhecimento prévio sobre o tamanho mínimo dos talhões. No caso dessa pesquisa, a área mínima considerada foi igual a 30 pixels, equivalente a aproximadamente um hectare. No entanto, a melhor combinação encontrada para os critérios de similaridade e área foi “34-50”, respectivamente. Assim, conclui-se que áreas menores que 1,62 ha não puderam ser individualizadas.

Deve-se ressaltar, no entanto, que o resultado da técnica de segmentação é um produto conjunto não só das dimensões e textura das classes temáticas envolvidas, mas, também, dos limiares de similaridade e área empregados, de forma que esses critérios não devem ser analisados isoladamente.

A Figura 38 mostra um detalhe ampliado da área de estudo, contendo o resultado da segmentação efetuada sobre a composição colorida CPa5 (R), CPa2 (G) e JERS (B). Pode-se observar que foram criadas regiões delimitando as classes “solo exposto” (1), “Pinus spp (maduro)” (2), “Eucalyptus spp” (3) e “mata nativa” (4).




FIGURA 38 – IMAGEM HÍBRIDA EM COMPOSIÇÃO COLORIDA RGB (CPa5, CPa2, JERS) SEGMENTADA. DETALHE DA ÁREA DE ESTUDO

4.3.4 Classificação Temática

A etapa de treinamento do classificador consistiu num procedimento interativo, com a atribuição de classes a algumas das regiões delimitadas pela segmentação. A classificação foi efetuada através do *software* SPRING, empregando como arquivo de contexto a composição apresentada na Figura 30 e a imagem segmentada.

Optou-se, nessa classificação, pela definição de duas classes adicionais, “corte recente” e “*Pinus spp* (maduro)”, em função de as mesmas terem sido detectadas na maioria dos produtos híbridos gerados pela fusão de dados. Na Figura 39 é apresentado o mapa de vegetação resultante da classificação por *Bhattacharyya*, submetido a um processo de pós-classificação e edição.

Em termos gerais pode-se considerar que o classificador foi eficiente, uma vez que as duas categorias predominantes, “*Pinus spp*” e “*Eucalyptus spp*”, foram bem delimitadas. Observa-se na porção leste da imagem que alguns talhões de *Pinus spp* foram erroneamente classificados como mata nativa por apresentarem enleiramento decorrente do preparo do terreno para o plantio. Nessas leiras houve regeneração de mata nativa, o que, de certa maneira, proporcionou uma competição com o dossel dos povoamentos, influenciando sua resposta espectral.

4.3.4.1 Acurácia temática

Os 292 pontos de referência, obtidos através do arquivo vetorial dos talhões, foram empregados para gerar a matriz de erros da classificação supervisionada (Tabela 21). A acurácia geral calculada foi igual a 82,53%, superior, portanto, aos valores obtidos para os sensores JERS1-SAR (60,19%) e LANDSAT-5 TM (73,3%), separadamente. O índice *kappa* (0,79) permitiu concluir que a classificação empregada gerou resultados 79% melhores do que aqueles que seriam obtidos com uma classificação aleatória, isto é, uma hipótese de nulidade H_0 , de que $\kappa=0$ (JENSEN, 1996). Segundo LANDIS e KOCH (1977), citados por MOREIRA (2001), valores da

estatística *kappa* situados entre 0,6 e 0,8 correspondem a uma qualidade do mapa temático avaliada como “muito boa”.

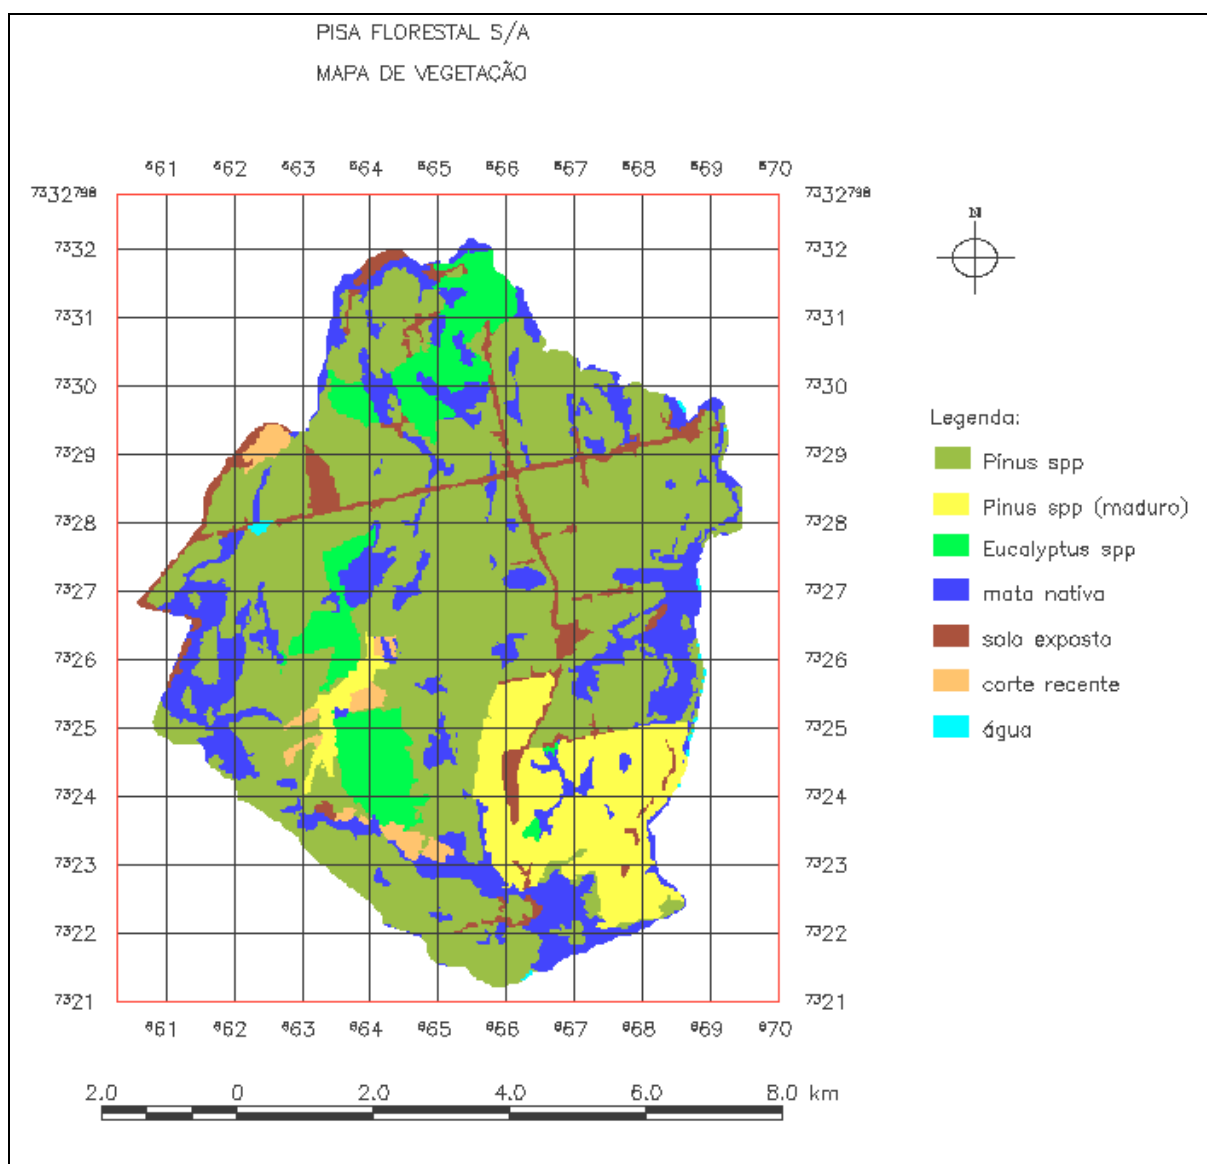


FIGURA 39 – MAPA DE VEGETAÇÃO DA ÁREA DE ESTUDO ELABORADO A PARTIR DE CLASSIFICAÇÃO SUPERVISIONADA DA IMAGEM HÍBRIDA “LANDSAT-5 TM / JERS1-SAR”

TABELA 21 – MATRIZ DE ERROS DA CLASSIFICAÇÃO SUPERVISIONADA DA IMAGEM HÍBRIDA LANDSAT-5 TM + JERS1-SAR

DADOS DE REFERÊNCIA ("verdade de campo")								
CLASSES	Solo exposto	Pinus spp (maduro)	Pinus spp	Eucalyptus spp	Mata nativa	Corte recente	Água	Total de linhas
Solo exposto	23	0	2	1	0	0	0	26
Pinus spp (maduro)	1	39	0	1	2	0	1	44
Pinus spp	3	0	48	0	16	2	3	72
Eucalyptus spp	0	0	1	50	4	0	0	55
Mata nativa	3	2	2	3	32	2	0	44
Corte recente	0	0	0	0	0	45	0	45
Água	2	0	0	0	0	0	4	6
Total das colunas	32	41	53	55	54	49	8	292

A análise dos valores encontrados para a acurácia do produtor revelou que os maiores erros de omissão se concentraram na classe “água” (50%), possivelmente devido ao baixo número de pontos de referência e à pouca representatividade dessa classe no terreno. As classes “Pinus spp (maduro)”, “corte recente”, “Eucalyptus spp” e “Pinus spp” apresentaram os menores erros de omissão, sempre inferiores a 10%.

A acurácia do produtor para “mata nativa” indica que 59,26% dos pixels de referência foram corretamente classificados, sendo que os 40,74% restantes foram atribuídos, principalmente, à classe “Pinus spp”. Isso se deve ao fato de que a maioria das áreas de mata nativa é circundada pelos talhões de *Pinus spp*.

Muitos dos pontos de referência para a classe “solo exposto” foram coletados sobre as estradas e aceiros transitáveis cuja largura, na imagem, é representada por um ou dois pixels, no máximo. Dessa forma, o erro de omissão de 28,22% para a referida

classe pode ser devido ao fato de esses pixels terem sido classificados como “mata nativa” e “Pinus spp”.

A análise da acurácia do usuário (Tab. 22) revelou que cerca de 34% das áreas indicadas como “Pinus spp” no mapa de vegetação na verdade pertencem a outras categorias no terreno, principalmente à classe “solo exposto”. Com base na matriz de erros pode-se afirmar que 100% das áreas classificadas como “corte recente” no mapa, representam efetivamente essa classe no terreno. Isso significa que nenhuma das outras categorias foi classificada erroneamente como “corte recente”. Os erros de comissão para as classes “Eucalyptus spp”, “Pinus spp (maduro)” e “solo exposto” situaram-se, na média, abaixo de 11%. Já para “mata nativa” o usuário do mapa deve considerar que 27,27% das áreas assim classificadas correspondem a outras classes, exceto a “água”.

TABELA 22 – ACURÁCIAS DO PRODUTOR E DO USUÁRIO POR CLASSE

CLASSES	ACURÁCIA DO PRODUTOR	ACURÁCIA DO USUÁRIO
Solo exposto	$23/32 * 100 = 71,88$	$23/26 * 100 = 88,46$
Pinus spp (maduro)	$39/41 * 100 = 95,12$	$39/44 * 100 = 88,64$
Pinus spp	$48/53 * 100 = 90,57$	$48/72 * 100 = 66,67$
Eucalyptus spp	$50/55 * 100 = 90,91$	$50/55 * 100 = 90,91$
Mata nativa	$32/54 * 100 = 59,26$	$32/44 * 100 = 72,73$
Corte recente	$45/49 * 100 = 91,84$	$45/45 * 100 = 100,00$
Água	$4/8 * 100 = 50,00$	$4/6 * 100 = 66,67$

5 CONCLUSÕES E RECOMENDAÇÕES

Em função dos resultados obtidos nesta pesquisa pode-se afirmar que a integração de imagens de sensores de microondas (JERS1-SAR) e ópticos (LANDSAT-5 TM) é tecnicamente viável para a elaboração de mapas temáticos e classificação de reflorestamentos de *Pinus spp* e *Eucalyptus spp*.

Com base nas análises efetuadas conclui-se:

- a) a correção geométrica da imagem JERS exigiu a aplicação do procedimento de ortorretificação para minimizar as distorções causadas pelo relevo e pela geometria de aquisição das imagens SAR;
- b) os *clusters* gerados a partir dos algoritmos de classificação não-supervisionada testados não puderam ser aproveitados como amostras de treinamento para a classificação híbrida;
- c) dentre os algoritmos de classificação supervisionada, o classificador por regiões que utiliza a distância de *Bhattacharyya* foi o que apresentou os melhores resultados, tanto para as imagens de cada sensor isoladamente, como para as imagens híbridas. Os valores da acurácia geral foram iguais a 60, 19%, 73,30 % e 82,53%, para a imagem JERS, LANDSAT-5 TM e híbrida, respectivamente;
- d) a integração das imagens JERS e LANDSAT-5 TM permitiu um aumento da acurácia temática em relação àquela obtida para cada sensor isoladamente, inclusive com a detecção de duas classes adicionais no produto híbrido;
- e) a segmentação de imagens revelou-se uma técnica promissora, especialmente no processamento de imagens JERS, em que o mapa temático foi elaborado a partir de um procedimento combinado envolvendo a atribuição de classes temáticas aos polígonos gerados pela segmentação;

- f) a intensa utilização das componentes principais, quer seja nos procedimentos de classificação, quer seja nos processos de integração de dados, demonstram a importância desta técnica no processamento digital de imagens. Deve-se ressaltar que, no presente estudo, as bandas resultantes dessa transformação estatística foram empregadas não com o intuito de reduzir a dimensionalidade dos dados, mas, sim, para discriminar alvos de interesse, não detectáveis nas bandas originais, isoladamente ou em composições coloridas;
- g) dentre as diferentes técnicas de fusão testadas, a mais facilmente implementada e a que produziu os melhores produtos híbridos foi a combinação simples da imagem JERS original e de componentes principais das bandas TM em composições coloridas RGB. As melhores composições foram aquelas em que se utilizou a banda do radar no canal vermelho (R) ou no azul (B);
- h) embora reconhecidamente um dos procedimentos mais utilizados na fusão de imagens de diferentes resoluções espaciais, a transformação IHS não produziu os resultados esperados. No entanto alguns dos produtos híbridos obtidos por esta técnica foram úteis na discriminação de alvos pontuais, tais como talhões cortados em diferentes épocas, talhões de diferentes idades e espécies do gênero *Pinus* e áreas com gramíneas e mata nativa;
- i) em termos gerais o melhor produto gerado pela transformação IHS envolveu bandas originais LANDSAT-5 TM e JERS e a primeira componente principal do conjunto formado pelas bandas dos dois sensores. Nesse caso a informação multiespectral associada à informação de relevo pode ser bastante útil na interpretação visual das imagens híbridas geradas;
- j) o processo de vetorização via tela produziu uma diferença média de 3,21% entre áreas reais e estimadas. Os maiores erros, contudo, foram apresentados por talhões localizados na porção *far-range* da imagem, cuja delimitação sofreu a influência da altura das árvores;

- k) o resultado da classificação temática supervisionada depende, em grande parte, da experiência e do conhecimento do analista a respeito da área de estudo e suas peculiaridades;
- l) a qualidade das imagens híbridas depende não somente da técnica de fusão empregada, mas, também, da precisão do registro entre as imagens a serem integradas;
- m) as técnicas de realce de contraste e atribuição das bandas aos canais RGB nas composições coloridas influenciam a qualidade do produto final e seus resultados tonais variam conforme o *software* utilizado;

Dada a relativa escassez de estudos sobre a resposta dos sensores de microondas em áreas de reflorestamentos, recomenda-se:

- a) utilizar os procedimentos metodológicos desenvolvidos nesta pesquisa para investigar outras aplicações de imagens de radar isoladamente ou em combinação com imagens de sensores ópticos, principalmente aquelas que se referem à estimativa da biomassa de reflorestamentos em função do coeficiente de retroespalhamento;
- b) efetuar novas pesquisas empregando imagens atuais para que, através de visitas a campo, sejam obtidas variáveis dendrométricas a serem correlacionadas com as informações espectrais;
- c) testar novas abordagens para a classificação de imagens de radar utilizando análise textural e outros algoritmos de segmentação de imagens;
- d) investigar a integração de imagens de radar e ópticas em regiões de reflorestamentos visando a recuperação de áreas de desinformação (nuvens e sombras) presentes nas imagens ópticas.

REFERÊNCIAS BIBLIOGRÁFICAS

AHERN, F.J. **Basic concepts of imaging radar: an intensive course**. São José dos Campos : Instituto Nacional de Pesquisas Espaciais, 1994. 117 p.

AHERN, F.J.; LECKIE, D.G.; DRIEMAN, J.A. Seasonal changes in relative C-Band backscatter of northern forest cover types. **IEEE Transactions on Geosciences and Remote Sensing**, v. 31, p. 668 – 680, 1993(a).

AHERN, F.J.; LECKIE, D.G.; WERLE, D. Applications of RADARSAT SAR data in forested environments. **Canadian Journal of Remote Sensing**, v. 19, n. 4, p.330 – 337, 1993(b).

AMARAL, S.; SHIMABUKURO, Y. E.; TOUTIN, T.; AHERN, F. Sensoriamento remoto por radar (SAR): pré-processamento de imagens RADARSAT (“fine mode”) na região da Floresta Nacional do Tapajós. In: **FIRST LATINO-AMERICAN SEMINAR ON RADAR REMOTE SENSING. IMAGE PROCESSING TECHNIQUES**, 1., 1996, Buenos Aires. **Proceedings ...**Noordwijk: ESA Publications Division, 1997. p.37-42.

ANDRADE, N.S. de O. **Qualidade geométrica de imagens JERS (SAR) e RADARSAT (modos S2 e S3) em ambiente de floresta tropical (Rondônia)**. São José dos Campos, 2000. 212 f. Dissertação (Mestrado em Sensoriamento Remoto) – Secretaria da Ciência e Tecnologia, Instituto Nacional de Pesquisas Espaciais (INPE).

ANTUNES, A.F.B. **Análise da textura em imagens de radar**. Disponível em: <http://www.cieg.ufpr.br/textura.html> Acesso em: 21 jun. 1999.

ANTUNES, A.F.B. **Análise do uso do processamento digital de imagens na segmentação de tipologias vegetais da APA de Guaraqueçaba – PR**. Curitiba, 1996. 109 f. Dissertação (Mestrado em Engenharia Florestal) – Setor de Ciências Agrárias, Universidade Federal do Paraná.

ARMAND, N. et al. Demonstration of application of JERS-1 data for estimation of forest state. In: SHIMADA, M. (Ed.). **JERS-1 Science Programme '99 PI Reports**. Global Forest Monitoring and SAR Interferometry. Tokyo : Earth Observation Research Center - NASDA, 1999. p.1 – 6.

ATKINSON, P. Preliminary Results of the Effect of Resampling on Thematic Mapper Imagery. ACSM- ASPRS. **Fall Convention Technical Papers**. Fall Church, Virginia: American Society for Photogrammetry and Remote Sensing and American Congress on Surveying and Mapping, 1985.

ATLAS do Estado do Paraná. Curitiba: Secretaria do Estado da Agricultura e do Abastecimento/ Instituto de Terras, Cartografia e Florestas, 1990.

EVERY, T.E.; BERLIN, G L. **Fundamentals of Remote Sensing and Airphoto Interpretation**. 5. ed.. Upper Saddle River: Prentice Hall, 1992. 472 p.

BARRET, E.C.; CURTIS, L.F. **Introduction to environmental remote sensing**. 4. ed. Cheltenham: Stanley Thornes Ltd., 1999. 457 p.

BIJKER, W. Radar for rainforest: a monitoring system for land cover change in the Colombian Amazon. In: INTERNATIONAL SEMINAR ON "THE USE AND APPLICATION OF ERS IN LATIN AMERICA", 1996, Viña del Mar. **Proceedings ... Noordwijk: ESA Publications Division, 1997. p. 53 – 60.**

BRASIL. Ministério da Ciência e Tecnologia: Comissão de Cartografia, 1986. Capítulo II. In: Cartografia, Aerolevanteamento e Legislação, Brasília, Brasil, p. 26 – 27.

BUSH, T.F.; ULABY, F.T. An Evaluation of Radar as a Crop Classifier. American Elsevier Publishing Company. **Remote Sensing of Environment**, v.07, n.01, p.15-36, 1978.

BUTERA, M.K. A correlation and regression analysis of percent canopy closure versus TMS spectral response for selected forest sites in the San Juan national Forest, Colorado. **IEEE Transactions on Geoscience and Remote Sensing**, v. 24, n. 1, p.122-129, 1986.

CÂMARA, G.; MEDEIROS, J.S. de. Mapas e suas representações computacionais. In: ASSAD, E. D.; SANO, E.E. (Ed.) **Sistema de informações geográficas**. Aplicações na agricultura. 2. ed. Brasília : Embrapa – SPI / Embrapa – CPAC, 1998. p. 13 – 29.

CAMPBELL, J.B. **Introduction to Remote Sensing**. 2nd. Ed. New York: The Guilford Press, 1996. 622 p.

CANADA Centre For Remote Sensing. ProRADAR. **Fundamental Concepts of Imaging Radar: Basic Level**. Canada: 1995.

CARVALHO, A. de S. **Integração de imagens de radar/JERS-1, TM/LANDSAT-5 e geofísicas para o mapeamento geológico da porção nordeste de Roraima, Brasil**. Brasília, 1997. 245 f. Tese (Doutorado em Geociências) – Instituto de Geociências, Universidade de Brasília (UNB).

CHAVEZ JR., P.S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, v. 24, n.3, p. 459-479, 1988.

CHURCHIL, P.; KEECH, M.A. Multi-frequency analysis of SAR-580 imagery for woodland determinations in Thetford Forest, England. In: SAR-580 INVESTIGATIONS' WORKSHOP, 1984, Ispra - Italy. **Proceedings ... Ispra : 1984.**

CHUVIECO, E. **Fundamentos de Teledetección Espacial**. Madrid : Ediciones Rialp S.A., 1990.

COLEMAN, T.L.; GUDAPATI, L.; DERRINGTON, J. Monitoring forest plantations using LANDSAT Thematic Mapper data. **Remote Sensing of Environment**, v. 33, p. 211-221, 1990.

COLEMAN, T.L.; GUDAPATI, L.; MASSAY, L.E. Assessment of LANDSAT Thematic Mapper imagery in differentiating among virgin and plantation pine stands. **In: Proceedings of the Twelfth Biennial Workshops on color Aerial Photography and Videography and Image Processing '89**, May 23-26, 1989. Reno, NV. Am. Soc. For Photogramm. And Remote Sens., Falls Church, VA. 1989.

COLEMAN, T.L.; MONTGOMERY, O.L. Soil Moisture, Organic Matter and Iron Content Effect on the Spectral Characteristics of Selected Vertisols and Alfisols in Alabama. **Photogrammetric Engineering and Remote Sensing**, v.53, n.12, p.1659-1663, 1987.

COLWELL, J.E. Vegetation Canopy Reflectance. **Remote Sensing of Environment**, v.03, n.03, p.175-183,1974.

CONWAY, J. Evaluating ERS-1 SAR data for the discrimination of tropical forest from other tropical vegetation types in Papua New Guinea. **International Journal Remote Sensing**, v. 18, n. 14, p. 2967-2984, 1997.

COSTA, S.M.F. da; CINTRA, J.P. Atualização cartográfica de mapas com imagens de satélite visando o reconhecimento de áreas urbanas. **In: IV CONFERÊNCIA LATINOAMERICANA SOBRE SISTEMAS DE INFORMAÇÃO GEOGRÁFICA E SIMPÓSIO BRASILEIRO DE GEOPROCESSAMENTO**, 4^o, 1993, São Paulo. **Anais...** São Paulo, Escola Politécnica da Universidade de São Paulo, 1993, p. 271-283.

COSTA et al. Classification of floodplains habitats (Lago Grande, Brazilian Amazon) with RADARSAT and JERS-1 data. **In : AHERN, F.J. (Ed.). RADARSAT for Amazonia: Results of ProRADAR investigations**. Ottawa : Canadian Centre for Remote Sensing, 1998(a), p.149 – 162.

COSTA et al. Seasonal dynamics of the Amazon Floodplain through radar eyes: Lago Grande de Monte Alegre case study. **In : AHERN, F.J. (Ed.). RADARSAT for Amazonia: Results of ProRADAR investigations**. Ottawa : Canadian Centre for Remote Sensing, 1998(b). p. 163 – 172.

CRACKNELL, A.P.; HAYES, L.W.B. **Introduction to Remote Sensing**. London: Taylor & Francis Ltd, 1993.

CRECHI, E.H. **Efeitos da densidade da plantação sobre a produção, crescimento e sobrevivência de *Araucaria angustifolia* (Bert.) O. Ktze. em Misiones, Argentina.** Curitiba, 1996. 172 f. Dissertação (Mestrado em Engenharia Florestal) – Setor de Ciências Agrárias, Universidade Federal do Paraná.

CROSTA, A.P. **Processamento digital de imagens de sensoriamento remoto.** Edição revisada. Instituto de Geociências. Unicamp. 1993. 170 p.

CROSTA, A.P.; SOUZA FILHO, C.R. Sensoriamento remoto. **Anuário Fator GIS 1997:** o guia de referência do geoprocessamento, Curitiba, v.1, p.c10-c21, 1997.

CURRAN, P.J.; KUPLICH, T.M. Temporal analysis of JERS-1/SAR images over regenerating forests in Brazilian Amazonia. In: SHIMADA, M. (Ed.). **JERS-1 Science Programme '99 PI Reports.** Global Forest Monitoring and SAR Interferometry. Tokyo : Earth Observation Research Center - NASDA, 1999. p. 18 – 22.

D'ALGE, J.C.L.; FERREIRA, N.A. Perspectivas de atualização do mapeamento sistemático através de imagens orbitais. In: V SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 5^o, 1988, Natal. **Anais...** São José dos Campos, Secretaria da Ciência e Tecnologia, Instituto Nacional de Pesquisas Espaciais/SELPER, 1988. p. 240-244.

DANSON, F.M. Preliminary evaluation of the relationship between SPOT-1 HRV data and forest stand parameters. **International Journal of Remote Sensing**, v. 8, n. 10, p.1571-1575, 1987.

DE COTIS, M. Termination of operation of Japanese Earth resources satellite JERS-1. National Space Development Agency of Japan News Release. **Florida Today Space Online.** Disponível em: <<http://www.flatoday.com/space>> Acesso em : 16 nov. 2000.

DE HOOGH, R.J.; DIETRICH, A.B.; AHRENS, S. Classificação de sítio, tabelas de volume e de produção para povoamentos artificiais de *Araucaria angustifolia*. **Brasil Florestal.** Brasília, v. 9, n. 36, p.58-82, 1978.

DOBSON, M.C.; ULABY, F.T.; PIERCE, L.E. Land cover classification of tropical rainforests using orbital SAR and impacts of natural and anthropogenic disturbance on species. In: SHIMADA, M. (Ed.). **JERS-1 Science Programme '99 PI Reports.** Global Forest Monitoring and SAR Interferometry. Tokyo : Earth Observation Research Center - NASDA, 1999. p.23 – 35.

DUCATI, J.R. et al. Classificação e quantificação de áreas de florestas no nordeste do Estado do Rio Grande do Sul, Brasil. In : IX SIMPOSIO LATINOAMERICANO DE PERCEPCIÓN REMOTA, 9. 2000, Puerto Iguazú. **Programa y resúmenes.** Luján : Editorial Universitaria – Universidad Nacional de Luján, 2000. p. 66-66.

DUPAS, C.A. SAR and LANDSAT TM image fusion for land cover classification in the brazilian Atlantic Forest domain. In: BEEK, K.J.; MOLENAAR, M. (Ed.). **International Archives of Photogrammetry and Remote Sensing**, v. XXXIII, part B1. Amsterdam : GITC, 2000. p. 96 – 103.

DUTRA, L.V. et al. The use of JERS-1 data for environment monitoring and resources assessment in Amazonia. In: SHIMADA, M. (Ed.). **JERS-1 Science Programme '99 PI Reports**. Global Forest Monitoring and SAR Interferometry. Tokyo : Earth Observation Research Center - NASDA, 1999. p. 36 – 44.

EASTMAN, J.R.; FULK, M. Long sequence time series evaluation using standardized principal components. **Photogrammetric Engineering and Remote Sensing**, v. 59, n.6, p. 991-996, 1993.

ELACHI, C. **Spaceborne Radar Remote Sensing: Applications and Techniques**. USA: IEEE Geoscience and Remote Sensing Society., 1987.

ENVI. The environment for visualizing images. **ENVI 3.1. Online tutorials**. Disponível em: < <http://www.envi/sw.com>.> Acesso em : 20 out. 2000.

EORC – Earth Observation Research Center. **JERS-1 Earth View**. NASDA. Tokyo. 1999.

ERDAS. **Erdas Field Guide**. Manual ERDAS Imagine 8.3. 4. ed. USA: 1997.

FERREIRA, N.A. **Um sistema para atualização de documentos cartográficos em ambientes de microcomputadores**. Rio de Janeiro, 1988. Dissertação (Mestrado em Cartografia) – Instituto Militar de Engenharia (IME).

FITCH, J.P. **Synthetic Aperture Radar**. New York : Springer-Verlag, 1988.

FRERY, A.C. **Algumas ferramentas estatísticas na síntese, processamento e análise de imagens de radar de abertura sintética**. São José dos Campos, 1993. Tese de Doutorado. Instituto Nacional de Pesquisas Espaciais.

FRITZ, L.W. The era of commercial earth observation satellites. **Photogrammetric Engineering and Remote Sensing**, v. 62, n.1, p.39-45, 1996

FROST, V.S.; STILES, J.A.; SHANMUGAN, K.S.; HOLTZMAN, J.C. A model for radar images and its application to adaptive digital filtering of multiplicative noise. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, PAMI-04, p.157-166. USA: 1982.

FUNG, A.K.; ULABY, F.T. **Matter-energy interaction in the microwave region**. Manual of Remote Sensing – Volume I. Second Edition. American Society of Photogrammetry, p.115-164. USA: 1983.

GELNETT, R.H. Importance of look direction and depression angles in geologic applications of SLAR. Technical Report **TR-04823**. Phoenix: MARS Associates. 1978.

GEWANDSZNAJDER, F. Aplicações da cartografia em sensoriamento remoto. In: V SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 5^o, 1988, Natal. **Anais...** São José dos Campos, Secretaria da Ciência e Tecnologia, Instituto Nacional de Pesquisas Espaciais/SELPER, 1988. p. 258-266.

GOLDBERG, A.M.; STONEY, W. **Land satellite information in the next decade**. Instrument data sheets. Greenbelt : MITRE – Center for Earth, Resources and Space, 1995, 74 p.

GOMEZ, J.R.P. Aporte en la interpretacion visual del uso de la tierra, dado por la combinacion del sensor pasivo TM LANDSAT-4 y el sensor activo SAR ERS-1. In: FIRST LATINO-AMERICAN SEMINAR ON RADAR REMOTE SENSING. IMAGE PROCESSING TECHNIQUES, 1., 1996, Buenos Aires. **Proceedings ...**Noordwijk: ESA Publications Division, 1997. p.133 – 140.

GONZALEZ, R.C.; WINTZ, P. **Digital image processing**. Massachussets : Addison-Wesley Publishing Company, 1977.

GUERRA, F. et al. Estimación de parámetros forestales en plantaciones comerciales de *Pinus caibaea* con datos JERS-1 SAR. In : IX SIMPOSIO LATINOAMERICANO DE PERCEPCIÓN REMOTA, 9. 2000, Puerto Iguazú. **Programa y resúmenes**. Luján : Editorial Universitaria – Universidad Nacional de Luján, 2000. p. 74-74.

GUPTA, R.P. **Remote sensing geology**. Berlin : Springer-Verlag, 1991.

HARALICK, R.M.; SHANMUGAN, K.; DINSTEN, I. Texture features for image classification. **IEEE Transactions on Systems, Man and Cybernetics**, n. 3, v. 6, p. 610-621, 1973.

HARRIS, J.; BOWIE, C.; RENCZ, A.; GRAHAM, D. Computer-enhancement techniques for the integration of remotely sensed, geophysical and thematic data for the geosciences. **Canadian Journal of Remote Sensing**, v. 20, n. 3, p. 210-221, 1994.

HARRIS, J.; MURRAY, R.; HIROSE, T. HIS transform for the integration of radar imagery and other remotely sensed data. **Photogrammetric Engineering and Remote Sensing**, v. 56, n. 12, p. 1631 – 1641, 1990.

HIROSAWA, H.; KOMIYAMA, S.; MATSUZAKA, Y. Cross-polarized radar backscatter from moist soil. **Remote Sensing of Environment**, v.07, n.03, p.211-217, 1978.

HOFFER, R.M. Biological and physical considerations in applying computer-aided analysis techniques to remote sensor data. In: Swain, P. H.; Davis, S.M. **Remote Sensing: The Quantitative Approach**. McGraw-Hill, Inc., 1978.

HORD, R.M. **Digital image processing of remotely sensed data**. New York : Academic Press, 1982.

HUNTER, G.T.; BIRD, S.J.G. Critical Terrain Analysis. **Photogrammetric Engineering and Remote Sensing**, v.36, n.09, p.939-952, 1970.

IBGE. **Geografia do Brasil: Região Sul**. v.2. Rio de Janeiro, 1990. 420 p.

IBGE. **Noções básicas de cartografia**. Rio de Janeiro: IBGE, Departamento de Cartografia, 1999. Manuais técnicos em geociências, N.8. 130 p.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **ATUS** – Atendimento ao usuário: Kit LANDSAT. Cachoeira Paulista. 1996. Catálogo.

JACSON, R.D.; HUETE, A.R. Interpreting vegetation indices. **Preventive Veterinary Medicine**, v.11, p. 185-200,1991.

JAGELS, R; TELEWSKI, F.W. Computer-aided imade analysis of tree rings. In: COOK, E.R.; KAIRIUKSTIS, L.A. (Eds.) **Methods of dendrochronology** – Applications in the environmental sciences. Dordrecht : Kluwer Academic Publishers, 1989. p. 76 – 93.

JENSEN, J.R. **Introductory digital image processing**. 2. ed. Upper Saddle River : Prentice Hall, 1996. 318 p.

JESUS, D. de. Uso de imagens de radar na Champion Amapá. In: SEMINÁRIO DE ATUALIZAÇÃO EM SENSORIAMENTO REMOTO E SISTEMAS DE INFORMAÇÕES GEOGRÁFICAS APLICADOS À ENGENHARIA FLORESTAL, III, 1998, Curitiba. **Anais**. Curitiba, Fundação de Pesquisas Florestais do Paraná, 1998. p. 149 – 156.

KANEMASU, E.T. Seasonal canopy reflectance patterns of wheat, sorghum, and soybean. **Remote Sensing of Environment**, v. 3, p.43-47, 1974.

KATTENBORN, G.; NEZRY, E.; DE GRANDI, G.; SIEBER, A.J. High resolution detection, monitoring and analysis of changes using ERS-1 SAR data. In: WORKSHOP ON “USE OF ERS-1 SAR DATA FOR AGRICULTURAL, FORESTRY AND ENVIRONMENTAL APPLICATIONS IN CENTRAL-EASTERN EUROPE”, 1993, Frascati, Italy. **Proceedings...** Frascati: ESA, 1994. p. 19-29.

KAZMIERCZAK, M.L. **Estimativa de variáveis dendrométricas em florestas homogêneas a partir de dados LANDSAT TM**. São José dos Campos, 1992. 186 f. Dissertação (Mestrado em Sensoriamento Remoto) – Secretaria da Ciência e da Tecnologia, Instituto Nacional de Pesquisas Espaciais.

KLEMAN, J. Directional reflectance factor distributions for two forest canopies. **Remote Sensing of Environment**, v. 23, n. 1, p. 83-96, 1987.

KLOER, B.R. Hybrid parametric/non-parametric image classification. **In: ACSM-ASPRS Annual Convencion**, April 1994. Reno, Nevada. 1994.

KRITIKOS, H.; YORINKS, L.; SMITH, H. Suspended solids analysis using ERTS-A data. **Remote Sensing of Environment**, v.3, n.1, p.69-78, 1974.

KUAN, D.T.; SAWCHUK, A.A.; STRAND, T.C.; CHAVEL, P. Adaptive restoration of images with speckle. **IEEE Transactions on Acoustics, Speech and Signal Processing**, ASSP-35, n.03, p.373-388. USA: 1987.

KUMAR, R. **Radiation from plants-reflection and emission: a review**. Lafayette : Purdue University, 1972. 88 p.

KURTZ, D.B. e LIGIER, H.D. Analisis espectral de montes forestales de la cuenca del Uruguay, Corrientes (Argentina). In : IX SIMPOSIO LATINOAMERICANO DE PERCEPCIÓN REMOTA, 9. 2000, Puerto Iguazú. **Programa y resúmenes**. Luján : Editorial Universitaria – Universidad Nacional de Luján, 2000. p. 56-56.

KUX, H; AHERN, F.; PIETSCH, R. Evaluation of radar remote sensing for natural resource management in the tropical rainforests of Acre State, Brazil. **Canadian Journal of Remote Sensing**, v. 21, n. 4, p. 430-440, 1995..

LANDGREBE, D.A., The quantitative approach: concept and rationale. In: Swain, P. H.; Davis, S.M. **Remote sensing: the quantitative approach**. New York, McGraw-Hill, 1978. 396p.

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

LAPOLLI, E.M. **Processamento de imagens digitais: uma abordagem utilizando conjuntos difusos**. (Tese de doutorado). Programa de Pós-Graduação em Engenharia de Produção. Universidade Federal de Santa Catarina. 1994.

LECKIE, D.G. Synergism of synthetic aperture radar and visible/infrared data for Forest type discrimination. **Photogrammetric Engineering and Remote Sensing**, v. 56, n. 9, p. 1237 – 1246, 1990.

LEE, J.S. A simple speckle smoothing algorithm for synthetic aperture radar images. **IEEE Transactions on Systems, Man and Cybernetic**, SMC-13, p. 85-89. USA:1981.

LEE, J.S.; JURKEVICH, I.; DEWAELE, P.; WAMBACQ, P.; OOSTERLINCK, A. Speckle filtering of synthetic aperture radar images: a review. **Remote Sensing Reviews**, v. 8, p. 313-340. 1994.

LICHTENEGGER, J. ESA's ERS Programme: A Summary Status Report on SAR Data Distribution and Applications. In: WORKSHOP ON "USE OF ERS-1 SAR DATA FOR AGRICULTURAL, FORESTRY AND ENVIRONMENTAL APPLICATIONS IN CENTRAL-EASTERN EUROPE", 1993, Frascati, Italy. **Proceedings...** Frascati: ESA, 1994. p. 5 –10.

LILLESAND, T.M.; KIEFER, R.W. **Remote Sensing and Image Interpretation**. 3rd. Edit. Crawfordsville: John Wiley and Sons, 1994, 750 p.

LIMA, M.I.C. de. **Introdução à interpretação radargeológica**. Rio de Janeiro: IBGE, Departamento de Recursos Naturais e Estudos Ambientais, 1995. Manuais técnicos em geociências, N.3. 124 p.

LINGNAU, C. Aplicação de imagens de satélite Landsat-5 TM para o monitoramento de danos causados pela vespa-da-madeira em reflorestamentos de *Pinus spp.* In: SEMINÁRIO DE ATUALIZAÇÃO EM SENSORIAMENTO REMOTO E SISTEMAS DE INFORMAÇÕES GEOGRÁFICAS APLICADOS À ENGENHARIA FLORESTAL, II, 1996, Curitiba. **Anais...** Curitiba, Fundação de Pesquisas Florestais do Paraná, 1996. p. 35-48.

LOCH, C. **Pesquisa de diversos sensores (Landsat, radar e fotos aéreas), bem como estudo de suas potencialidades aplicadas à interpretação geológica**. Curitiba, 1982. 118 f. Dissertação (Mestrado em Ciências Geodésicas) – Universidade Federal do Paraná.

LOCH, R.E.N. **Integração das técnicas de sensoriamento remoto e SIG para a estruturação de um banco de dados espaciais, temático e temporal para áreas degradadas pela mineração**. Curitiba, 2000. 206 f. Tese (Doutorado em Ciências Florestais) – Setor de Ciências Agrárias, Universidade Federal do Paraná.

LOUGHLIN, W.P. Principal component analysis for alteration mapping. **Photogrammetric Engineering and Remote Sensing**, v. 57, n. 9, p. 1163-1169, 1991.

LUCCA, E.V.D.; FREITAS, C.C.; FRERY, A.C.; SANT'ANNA, S.J.S. Comparison of SAR segmentation algorithms. In: SECOND LATINO-AMERICAN SEMINAR ON RADAR REMOTE SENSING. IMAGE PROCESSING TECHNIQUES, 2., 1998, Santos. **Proceedings ...** Noordwijk : ESA Publications Division, 1998. p. 123 - 130.

LUCKMAN, A.; BAKER, J.R.; HONSÁK, M; LUCAS, R. Tropical forest biomass density estimation using JERS-1 SAR: seasonal variation, confidence limits and application to image mosaics. In: SHIMADA, M. (Ed.). **JERS-1 Science Programme '99 PI Reports**. Global Forest Monitoring and SAR Interferometry. Tokyo : Earth Observation Research Center - NASDA, 1999. p. 75 – 84.

LUZ, N.B. da; LINGNAU, C. **Avaliação das características texturais de uma imagem Landsat-5 TM para fins de plano de manejo da Estação Ecológica do Rio Guarani**. Disponível em <http://200.17.237/online/arquivo1/9.htm> Acesso em: 28 out. 2000.

LYBANON, M. **Processing for spaceborne synthetic aperture radar imagery**. National Aeronautics and Space Administration (NASA). Washington D.C.: 1973.

MAACK, R. **Geografia física do Estado do Paraná**. 2. ed. Rio de Janeiro : J. Olympio, 1981, 450 p.

MANORE, M.; D'IORIO, M.; HARRIS, J. SAR Data Fusion. In: FIRST LATINO-AMERICAN SEMINAR ON RADAR REMOTE SENSING. IMAGE PROCESSING TECHNIQUES, 1., 1996, Buenos Aires. **Proceedings ...**Noordwijk: ESA Publications Division, 1997. p. 91-96.

MARDIA, K.V.; KENT, J.T.; BIBBY, J.M. **Multivariate analysis**. London : Academic Press, 1979.

MASCARENHAS, N.D.A. An overview of speckle noise filtering in SAR images. In: FIRST LATINO-AMERICAN SEMINAR ON RADAR REMOTE SENSING. IMAGE PROCESSING TECHNIQUES, 1., 1996, Buenos Aires. **Proceedings ...**Noordwijk: ESA Publications Division, 1997. p. 71-79.

MATHER, P.M. **Computer processing of remotely sensed images**. An introduction. 2. ed. Chichester : John Wiley & Sons, 1999.

MOORE, R.K.; FUNG, A.K. Radar determination of winds at sea. **IEEE Proceedings**, v. 67, n. 11, p. 1504-1521, 1979.

MOREAU, S.; BOURREL, L. Hydrogeodynamics of the wetlands in the Bolivian Amazon Basin. In : AHERN, F.J. (Ed.). **RADARSAT for Amazonia: Results of ProRADAR investigations**. Ottawa : Canadian Centre for Remote Sensing, 1998. p.193 – 198.

MOREIRA, M.A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. São José dos Campos : Instituto Nacional de Pesquisas Espaciais (INPE), 2001.

NADOLNY, M.C. **Aplicabilidade de um sistema de informações geográficas e imagens de sensor aerotransportável para planejamento florestal**. Curitiba, 1995. 124 f. Dissertação (Mestrado em Ciências Florestais) – Setor de Ciências Agrárias, Universidade Federal do Paraná.

NAGAO, M.; MATSUYAMA, T. Edge preserving smoothing. **Computer Graphics and Image Processing**, v. 9, p. 394 – 407, 1979.

NASCIMENTO, P.S. de R; ALMEIDA FILHO, R. Utilização da técnica de segmentação em imagens TM/Landsat visando otimizar a técnica de interpretação visual. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador. **Artigos**. São José dos Campos : INPE/SELPER, 1996. 1 CD-ROM.

NEZRIT, E.; DEMARGNE, L. Using Spot and radar data to inventory forests in Sarawak. **Your application – Forestry**. Disponível em <http://www.spot.com.home/appli> . Acesso em 23/Nov./2000

NOVO, E.M.L.M. **Sensoriamento Remoto – Princípios e Aplicações**. 2ª edição. São Paulo: Edgard Blücher, 1995. 308 p.

OLIVEIRA, Y.M.M. de. **Investigation of remote sensing for assessing and monitoring the Araucaria Forest region of Brazil**. Oxford, 2000. 247 f. Thesis (Doctor of Philosophy) – Department of Plant Sciences, University of Oxford.

PALME, U. Radares imageadores em sensoriamento remoto. **Anuário Fator GIS 1997**: o guia de referência do geoprocessamento, Curitiba, v.1., p.c28-c34. 1997.

PÉLLICO NETTO, S.; BRENA, D.A. **Inventário florestal**. Curitiba : Universidade Federal do Paraná/Universidade Federal de Santa Maria, 1993. 271 p.

PITT, D.G.; WAGNER, R.G.; HALL, R.J.; KING, D.J.; LECKIE, D.G.; RUNESSON, U. 1977. Use of Remote Sensing for Forest Vegetation Management: A Problem Analysis. **The Forestry Chronicle.**, v. 73, n.4, p.459-477, 1997.

POHL, C. **Geometric aspects of multisensor image fusion for topographic map updating in the humid tropics**. Hannover, 1996. 158 f. Tese (Doutorado em Engenharia Civil) – Universidade de Hannover.

PONZONI, F.J. **Aplicação do modelo SAIL no estudo da reflectância espectral de dosséis de mudas de *Eucalyptus sp* e de *Aspidosperma sp***. Curitiba, 1993. 206 f. Tese (Doutorado em Engenharia Florestal) – Universidade Federal do Paraná.

PRATT, W.K. **Digital image processing**. New York : John Wiley & Sons, 1991.

QUEGAN, S. Segmentation and classification in SAR imagery. In: FIRST LATINO-AMERICAN SEMINAR ON RADAR REMOTE SENSING. IMAGE PROCESSING TECHNIQUES, 1., 1996, Buenos Aires. **Proceedings ...**Noordwijk: ESA Publications Division, 1997. p. 141 - 151.

RADARSAT International. **RADARSAT ILLUMINATED – Your Guide to Products and services.** Canada: 1995.

RANSON, K.J; SUN, G. Mapping biomass of a northern forest using multifrequency DAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 32, n.2, p. 388 –396, 1994.

RAO, P.V.N.; VIDYADHAR, M.S.R.R.; RAO, T.Ch. M.; VENKATARATNAM, L. An Adaptative Filter for Speckle Suppression in Synthetic Aperture Radar Images. **International Journal of Remote Sensing**, v.16, n.05, p.877-889, 1995.

RAO, V.R.; BRACH, E.J.; MACK, A.R. Bidirectional reflectance of crops and the soil contribution. **Remote Sensing of Environment**, v.08, n.02, p.115-125, 1979.

RENNÓ, C.D.; SOARES, J.V. Utilização de medidas texturais na discriminação de classes de uso do solo do perímetro irrigado de Bebedouro, Pernambuco, Brasil, utilizando-se imagens SAR. In: FIRST LATINO-AMERICAN SEMINAR ON RADAR REMOTE SENSING. IMAGE PROCESSING TECHNIQUES, 1., 1996, Buenos Aires. **Proceedings ...**Noordwijk: ESA Publications Division, 1997. p. 171-177.

RICHARDS, J.A. **Remote sensing digital images analysis: an introduction.** Berlin : Springer-Verlag, 1986. 281 p.

ROSA, R. **Introdução ao sensoriamento remoto.** 3^a Edição.Uberlândia : Edufu, 1995. 117p.

ROSOT, N.C; ROSOT, M.A.D.; LOCH, C. Integração de dados LANDSAT TM e SPOT HRV para o monitoramento ambiental. In: ENCONTRO DE CADASTRO TÉCNICO MULTIFINALITÁRIO PARA OS PAÍSES DO CONESUL, 1., 2000, Florianópolis. **Anais ...** Florianópolis : UFSC, 2000. 1 CDROM.

ROSOT, N.C.; KELLER, D.; MALESKI, D.; HERBST, A.O. **Potencialidade de imagens de radar para atualização cartográfica de áreas de reflorestamentos no Estado do Paraná.** Curitiba, 2001. 85 p. Monografia (Especialização em Geoprocessamento) – Centro Integrado de Estudos em Geoprocessamento (CIEG), Universidade Federal do Paraná.

ROUGHGARDEN, J.; RUNNING, S.W.; MATSON, P.A. What does remote sensing do for Ecology? **Ecology**, v. 72, n.6,p.1918-1922, 1991.

SABINS, F.F. **Remote sensing: principles and interpretation**. São Francisco : W.H Freeman, 1997.

SALAS, W.A.; RIGNOT, E.; SKOLE, D. Use of JERS-1 SAR for monitoring deforestation and secondary growth in the tropics. In: SHIMADA, M. (Ed.). **JERS-1 Science Programme '99 PI Reports**. Global Forest Monitoring and SAR Interferometry. Tokyo : Earth Observation Research Center - NASDA, 1999. p. 123-132.

SALOMONSON, V.V.; JACKSON, T.J.; LUCAS, J.R.; MOORE, G.K.; RANGO, A.; SCHMUGGE, T; SCHOLZ, D. **Water resources assessment**. Manual of Remote Sensing – Volume II. Second Edition. American Society of Photogrammetry, p.1497-1570. USA: 1983.

SANO, E.E.; PINHEIRO, G.G.C.; MENESES, P.R. Assessing JERS-1 Synthetic Aperture Radar Data for Vegetation Mapping in the Brazilian Savanna. (não-publicado). Submetido ao **Journal of the Remote Sensing Society of Japan** em outubro/1999.

SANO, E.E.; LUIZ, A .J.B.; ASSAD, E.D.; BEZERRA, H.S.; MOREIRA, L. Estimativa de erros cometidos pelo Sistema de Informações Geográficas SGI na medida de áreas de polígonos. In: IV CONFERÊNCIA LATINOAMERICANA SOBRE SISTEMAS DE INFORMAÇÃO GEOGRÁFICA E SIMPÓSIO BRASILEIRO DE GEOPROCESSAMENTO, 2^o, 1993, São Paulo. **Anais...** São Paulo, Escola Politécnica da Universidade de São Paulo, 1993. p. 105-120.

SANT'ANNA, S.J.S.; YANASSE, C.C.F.; FRERY, A.C. Estudo comparativo de alguns classificadores utilizando-se imagens Radarsat da região de Tapajós. In: FIRST LATINO-AMERICAN SEMINAR ON RADAR REMOTE SENSING. IMAGE PROCESSING TECHNIQUES, 1., 1996, Buenos Aires. **Proceedings ...**Noordwijk: ESA Publications Division, 1997. p. 187-194.

SANTOS, J.R. dos. **Biomassa aérea da vegetação de cerrado: estimativa e correlação com dados do sensor Thematic Mapper do satélite LANDSAT**. Curitiba, 1988. 156 p. Tese (Doutorado em Engenharia Florestal) – Setor de Ciências Agrárias, Universidade Federal do Paraná.

SANTOS, J.R. dos; LACRUZ, M.S.P. Técnicas de extração de informações para monitoramento da biomassa florestal: a contribuição de imagens ópticas e de microondas. In: SEMINÁRIO DE ATUALIZAÇÃO EM SENSORIAMENTO REMOTO E SISTEMAS DE INFORMAÇÕES GEOGRÁFICAS APLICADOS À ENGENHARIA FLORESTAL, III, 1998, Curitiba. **Anais...** Curitiba, Fundação de Pesquisas Florestais do Paraná, 1998. p. 31-44.

SCALES, D.; KEIL, M.; SCHMIDT, M.; KUX, H.; SANTOS, J.R.dos. Use of multitemporal ERS-1 SAR data for rainforest monitoring in Acre, Brazil, within a german/brazilian cooperation project. In: INTERNATIONAL SEMINAR ON “THE USE AND APPLICATION OF ERS IN LATIN AMERICA”, 1996, Vina del Mar. **Proceedings** ... Noordwijk: ESA Publications Division, 1997. p. 37 – 43.

SCHMIDT, M.; KEIL, M.; SCALES, D.; SCHMIDT, M.; SANTOS, J.R.dos; KUX, H. Investigation of deforestation dynamics and landuse changes by ERS-1 SAR data in Rondonia, Brazil. In: INTERNATIONAL SEMINAR ON “THE USE AND APPLICATION OF ERS IN LATIN AMERICA”, 1996, Vina del Mar. **Proceedings** ... Noordwijk: ESA Publications Division, 1997. p. 45 – 52.

SCHOWENGERDT, R.A. **Remote sensing: model and methods for image processing**. London : Academic Press Inc, 1997. 522 p.

SHIMABUKURO, Y.; AMARAL, S.; AHERN, F.J.; PIETSCH, R.W. Classification and monitoring the Tapajós National Forest region using SAR (RADARSAT – standard mode and SAREX – wide swath mode) and LANDSAT Thematic Mapper data. In : AHERN, F.J. (Ed.). **RADARSAT for Amazonia: Results of ProRADAR investigations**. Ottawa : Canadian Centre for Remote Sensing, 1998. p. 103 – 109.

SHIMABUKURO, Y.E.; HERNANDEZ FILHO, P.; LEE, D.C.L. Análise de dados do TM/LANDSAT para levantamento de reflorestamento. In: SIMPÓSIO LATINO-AMERICANO DE SENSORIAMENTO REMOTO, 4., REUNIÃO PLENÁRIA SELPER, 9., CONFERÊNCIA SELPER SOBRE AVHRR, 1., 1989, Bariloche. **Anais** ... Bariloche : SELPER, 1989. t.1, p.263-271.

SILVA JR., A.F. da. **Combinação de imagens RADARSAT e LANDSAT-5 TM para fins de mapeamento geo-ambiental**. Curitiba, 1999. 113 f. Dissertação (Mestrado em Ciências Geodésicas) – Setor de Ciências Exatas, Universidade Federal do Paraná.

SILVA, E.L.S.; PONZONI, F.J. Comparação entre a reflectância hemisférica de folhas e a reflectância bidirecional de um dossel. **Revista Árvore**, v.19, n.4, p.466-478. 1995.

SILVA, J. de C. Perspectivas do setor florestal. **Revista da Madeira**, n. 50, p. 8 – 12, 2000.

SILVEIRA, P. **Detecção de alterações na cobertura vegetal ocasionadas pela expansão urbana em uma região do litoral paranaense, através de técnicas de sensoriamento remoto**. Curitiba, 1997. 110 f. Dissertação (Mestrado em Ciências Florestais) – Setor de Ciências Agrárias, Universidade Federal do Paraná.

SIMONETT, D.S.: DAVIS, R.E. **Image analysis-active microwave**. Manual of Remote Sensing – Volume I. Second Edition. American Society of Photogrammetry, p. 1125- 1181. USA: 1983.

SMITH, J.A. **Matter-Energy Interaction in the Optical Region**. In: Manual of Remote Sensing – Volume I. Second Edition. American Society of Photogrammetry, p.61-164. USA:1983.

SOARES, S.M. **Classificação textural de imagens SAR, por modelagem autorregressiva**. São José dos Campos, 1998. 195 f. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais.

SOARES, S.M.; SANT'ANNA, S.J.; KUNTSCHIK, G. Integração de dados multiespectrais landsat-5 TM com imagens SAR JERS-1, para fins cartográficos. In: FIRST LATINO-AMERICAN SEMINAR ON RADAR REMOTE SENSING. IMAGE PROCESSING TECHNIQUES, 1., 1996, Buenos Aires. **Proceedings** ...Noordwijk: ESA Publications Division, 1997. p. 115-123.

SOUSA, C.L. **Avaliação de imagens-índice e de imagens-proporção para detecção de alteração no volume de madeira em florestas implantadas**. São José dos Campos, 1997. 102 p. Dissertação (Mestrado em Sensoriamento Remoto) – Secretaria da Ciência e da Tecnologia, Instituto Nacional de Pesquisas Espaciais.

SOUSA, E.B. **Técnicas de processamento de imagens aplicadas à localização de solos lateríticos**. São José dos Campos : ITA, 1996. Dissertação de Mestrado.

SPRING – Sistema de processamento de informações georreferenciadas. São José dos Campos : NETGIS, 1998 (a). v. 2: Processamento de imagens.

SPRING – Sistema de processamento de informações georreferenciadas. São José dos Campos : NETGIS, 1998 (b). v. 3: Modelagem, análise e consulta espacial.

STONER, E.R.; BAUMGARDNER, M.E. Characteristic variations in the reflectance of surface soils. **Soil Science Society of American Journal**, n.45, p.1161-1165, 1981.

SWAIN, P.H.;DAVIS, S.M. **Remote sensing: the quantitative approach**. New York : McGraw Hill, 1978.

SZEKIELDA, K. **Satellite monitoring of the earth**. New York: John Wiley, 1988. 326 p.

TOUTIN, T.; AMARAL, S. Measuring clearings and tree heights with stereo RADARSAT data in a tropical forest environment. In : AHERN, F.J. (Ed.). **RADARSAT for Amazonia: Results of ProRADAR investigations**. Ottawa : Canadian Centre for Remote Sensing, 1998. p.117 – 124.

ULABY, F. T.; LI, R. Y.; SHANMUGAN, K.S. Crop classification using airborne radar and Landsat data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 20, n. 1, p.42-51, 1982.

ULABY, F.T.; BATLIVALA, P.P.; BARE, J.E. Crop identification with L-Band radar. **Photogrammetric Engineering and Remote Sensing**, v.46, n.01, p.101-106. American Society for Photogrammetry and Remote Sensing. 1980.

ULABY, F.T.; CIHLAR, J.; MOORE, R.K. Active microwave measurement of soil water content. **Remote Sensing of Environment**, v.3, p.185-203. American Elsevier Publishing Company. 1974.

ULABY, F.T.; KOUYATE, F.; BRISCO, B. LEE WILLIAMS, T.H. Textural information in SAR images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 24, n. 2, p. 235-245. 1986

ULABY, F.T.; MOORE, R.K.; FUNG, A.K. **Microwave remote sensing**. Active and passive. Volume 1: Microwave remote sensing fundamentals and radiometry. Boston : Addison Wesley Publishing Company. 1981.

USDA FOREST SERVICE. **Guidelines for the use of digital imagery for vegetation mapping**. Washington : USDA Forest Service / Engineering Staff, 1995. 125 p.

VALLE, H.F. del; ELISSALDE, N.O.; GAGLIARDINI, D.A. ERS-1/SAR and SPOT data for irrigated land evaluations in a sector of the Chubut Inferior Valley (Central Patagonia, Argentina). In: INTERNATIONAL SEMINAR ON "THE USE AND APPLICATION OF ERS IN LATIN AMERICA", 1996, Vina del Mar. **Proceedings ... Noordwijk: ESA Publications Division, 1997. p. 89 – 92.**

VENTURIERI, A.; SANTOS, J.R. Técnicas de classificação de imagens para análise de cobertura vegetal. In: ASSAD, E. D.; SANO, E.E. (Ed.) **Sistema de informações geográficas**. Aplicações na agricultura. 2. ed. Brasília : Embrapa – SPI / Embrapa – CPAC, 1998. p. 351 – 371.

VERBYLA, D.L. **Satellite remote sensing of natural resources**. Boca Raton : CRC Press, 1995.

VERGARA, O.R.; KURKDJIAN, M. de L. N. de O.; PEREIRA, M.N. Contribuição dos dados SPOT analógicos para a atualização de cartas topográficas na escala 1:50.000. In: VII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 7^o, 1993, Curitiba. **Anais...** São José dos Campos, Secretaria da Ciência e Tecnologia, Instituto Nacional de Pesquisas Espaciais, 1993. p. 390-399.

VIEIRA, P.R. **Desenvolvimento de classificadores de máxima verossimilhança e ICM para imagens SAR**. São José dos Campos, 1996. 227 p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais.

VRABEL, J. Multispectral imagery band sharpening study. **Photogrammetric Engineering and Remote Sensing**, v. 62, p. 1075-1084. 1996.

WERKEMA, M.C.C. **Como estabelecer conclusões com confiança: entendendo inferência estatística**. Belo Horizonte : Fundação Christiano Ottoni, Escola de Engenharia da UFMG, 1996. 309 p.

WU, S.T. Potential application of multipolarization sar for pine plantation biomass estimation. **IEEE Transactions on Geoscience and Remote Sensing**, vol. GE-25, n. 3, p. 403-409. 1987.

APÊNDICES

REGISTRO JERS-LANDSAT (Pontos de controle)

Total RMS Error: 0.426320

ID# (Base X,Y)(Warp X,Y):(Predict X,Y)	(Error X,Y)(RMS)
#1 (374.45,199.82)(266.36,129.36):(266.63,129.44)	(0.27,0.08)(0.28)
#2 (198.42,173.50)(160.53,112.47):(160.46,112.42)	(-0.07,-0.05)(0.08)
#3 (208.53,233.41)(167.44,148.50):(167.56,148.78)	(0.12,0.28)(0.31)
#4 (67.50,305.88)(85.45,192.55):(85.61,192.19)	(0.16,-0.36)(0.40)
#5 (111.90,320.20)(112.36,200.45):(112.17,201.05)	(-0.19,0.60)(0.63)
#6 (409.58,100.75)(288.07,69.57):(288.11,70.10)	(0.04,0.53)(0.53)
#7 (330.13,92.13)(239.73,64.82):(239.56,64.24)	(-0.17,-0.58)(0.61)
#8 (389.50,252.45)(275.50,161.36):(275.57,161.19)	(0.07,-0.17)(0.19)
#9 (414.55,343.55)(290.50,216.57):(290.08,216.05)	(-0.42,-0.52)(0.67)
#10 (383.38,424.50)(271.50,264.43):(271.72,264.68)	(0.22,0.25)(0.33)
#11 (224.46,388.46)(179.38,242.46):(179.40,242.74)	(0.02,0.28)(0.28)
#12 (67.50,430.67)(89.55,268.55):(89.49,268.21)	(-0.06,-0.34)(0.35)

Segmento ORBIT

```

SatelliteDesc      :
SceneID            : J1S0000129
SatelliteSensor    : SAR-1
SensorNumber       : 1
DateImageTaken     : 18/12/1995
SupSegExist        : FALSE
FieldOfView        : 1.47661963901813E-05
ViewAngle          : -6.10865238198015E-01
NumColCentre       : 3.200000000000000E+03
RadialSpeed        : 6.31253589629013E+00
Eccentricity       : 8.18201802494580E-02
Height             : 5.680230000000000E+05
Inclination        : 1.70452345408270E+00
TimeInterval       : 1.80032654545594E-03
NumLineCentre      : 3.000000000000000E+03
LongCentre         : -8.63295443754388E-01
AngularSpd         : 1.08816628852436E-03
AscNodeLong        : 2.35207609868392E+00
ArgPerigee         : 1.57079632679490E+00
LatCentre          : -4.22594498334236E-01
EarthSatelliteDist : 6.95097228137754E+06
NominalPitch       : 0.000000000000000E+00
TimeAtCentre       : 4.85963109999895E+04
SatelliteArg       : 3.57616761419868E+00
XCentre            : 3.200000000000000E+03
YCentre            : 3.000000000000000E+03
UtmXCentre         : 6.56065363552590E+05
UtmYCentre         : 7.32134567343220E+06
PixelRes           : 1.250000000000000E+01
LineRes            : 1.250000000000000E+01
CornerAvail        : TRUE
  
```

```

MapUnit      : UTM      22 C E008
XUL          : 1.0000000000000000E+00
YUL          : 1.0000000000000000E+00
XUR          : 6.0000000000000000E+03
YUR          : 1.0000000000000000E+00
XLR          : 6.0000000000000000E+03
YLR          : 6.4000000000000000E+03
XLL          : 1.0000000000000000E+00
YLL          : 6.4000000000000000E+03
UtmXUL      : 6.26290051428040E+05
UtmYUL      : 7.36738173475010E+06
UtmXUR      : 7.03929243754510E+05
UtmYUR      : 7.34810349381130E+06
UtmXLR      : 6.85855813723060E+05
UtmYLR      : 7.27531872500790E+06
UtmXLL      : 6.08216618668430E+05
UtmYLL      : 7.29459697176210E+06
LongCentreDeg : -4.9463185E+01
LatCentreDeg  : -2.4212881E+01
LongUL       : -4.9760321E+01
LatUL        : -2.3799845E+01
LongUR       : -4.8995818E+01
LatUR        : -2.3965865E+01
LongLR       : -4.9163936E+01
LatLR        : -2.4625132E+01
LongLL       : -4.9932263E+01
LatLL        : -2.4458456E+01
ImageRecordLength : 12192
NumberImageLine : 6400
NumberBytePerPixel : 2
NumberSamplePerLine : 6000
NumberPrefixData : 180
NumberSuffixData : 0
Type          : NO_DATA

```