

**AVALIAÇÃO DOS MODELOS DE MISTURA
ESPECTRAL MESMA E SMA APLICADOS
AOS DADOS HIPERESPECTRAIS
HYPERION/EO-1 ADQUIRIDOS NA
PLANÍCIE COSTEIRA
DO RIO GRANDE DO SUL**

RODRIGO DE MARSILLAC LINN

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL - UFRGS
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E
METEOROLOGIA - CEP SRM
PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

**AVALIAÇÃO DOS MODELOS DE MISTURA ESPECTRAL MESMA E SMA
APLICADOS AOS DADOS HIPERESPECTRAIS HYPERION/EO-1
ADQUIRIDOS NA PLANÍCIE COSTEIRA DO RIO GRANDE DO SUL**

RODRIGO DE MARSILLAC LINN

Orientadora: Dr^a. Sílvia B. A. Rolim
Co-orientador: Dr. Lênio Soares Galvão

Porto Alegre

2008

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL - UFRGS
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E
METEOROLOGIA - CEP SRM
PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

**AVALIAÇÃO DOS MODELOS DE MISTURA ESPECTRAL MESMA E SMA
APLICADOS AOS DADOS HIPERESPECTRAIS HYPERION/EO-1
ADQUIRIDOS NA PLANÍCIE COSTEIRA DO RIO GRANDE DO SUL**

Rodrigo de Marsillac Linn

Orientador: Profa. Dra. Sílvia Beatriz Alves Rolim - UFRGS

Co-orientador: Prof. Dr. Lênio Soares Galvão – INPE

Dissertação submetida ao Programa de Pós-Graduação em Sensoriamento Remoto como requisito parcial para a obtenção do título de Mestre em Sensoriamento Remoto.

Banca examinadora:

Prof. Dr. Vitor F. A. Haertel – UFRGS

Prof. Dr. Waerloo Pereira Filho – UFSM

Prof. Dr. Carlos Roberto de Souza Filho - UNICAMP

Porto Alegre

2008

"Mãos de homens e de povos que se estendam menos em gestos de súplica,
e se vão fazendo cada vez mais,
mãos humanas que transformem o mundo..."

PAULO FREIRE

AGRADECIMENTOS

Aos meus orientadores Prof^a. Dr^a. Sílvia B. A. Rolim e Prof. Dr. Lênio Soares Galvão, pelo conhecimento transmitido, pela orientação e ajuda na realização deste trabalho.

À minha esposa Luiziane, pelo incentivo, paciência e companheirismo.

Aos meus amados filhos Thiago, Lucas e Gabriel, fontes de inesgotável energia, inspiração e alegria.

Aos meus pais Pedro e Marília, pela confiança e incentivo.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES, pela bolsa de estudos concedida.

Ao Programa Nacional de Cooperação Acadêmica - PROCAD, por permitir intercâmbio com o Programa de Mestrado em Sensoriamento Remoto do INPE.

Aos professores, funcionários, colegas e amigos do PPGSR/UFRGS, em especial à colega Cristina Sutil, pelos esclarecimentos e sugestões “geológicas”.

Ao Ramon Freitas (INPE), pela programação em MatLab.

A todas as pessoas que contribuíram de forma direta ou indireta para a realização deste trabalho.

AVALIAÇÃO DOS MODELOS DE MISTURA MESMA E SMA APLICADOS AOS DADOS HIPERESPECTRAIS HYPERION/EO-1 ADQUIRIDOS NA PLANÍCIE COSTEIRA DO RIO GRANDE DO SUL*

RESUMO

O objetivo do presente trabalho foi avaliar o uso potencial dos dados hiperespectrais do sensor orbital Hyperion/Earth Observing One (EO-1) e dos modelos de mistura espectral MESMA (*Multiple Endmember Spectral Mixture Analysis*) e SMA (*Spectral Mixture Analysis*) para discriminação de classes de cobertura da Planície Costeira do Rio Grande do Sul. O modelo MESMA difere do SMA por permitir que o número e o tipo de Membros de Referência (MRs), assim como sua abundância, variem pixel a pixel. A abordagem metodológica utilizada envolveu as seguintes etapas: (a) pré-processamento dos dados Hyperion e conversão dos valores de radiância para imagens atmosféricamente corrigidas de reflectância de superfície; (b) uso sequencial das técnicas *Minimum Noise Fraction* (MNF), *Pixel Purity Index* (PPI) e Visualizador *n*-Dimensional, no intervalo de 454 a 2334 nm, para seleção inicial de um grupo de pixels candidatos a MRs (primeira biblioteca espectral) e de um outro grupo para fins de validação dos modelos; (c) uso do aplicativo VIPER (*Visualization and Image Processing for Environmental Research*) Tools para refinamento da primeira biblioteca espectral e seleção final dos MRs, utilizando as métricas EAR (*Endmember Average RMSE*), MASA (*Minimum Average Spectral Angle*) e CoB (*Count Based Endmember Selection*); (d) geração dos modelos MESMA e SMA com o VIPER Tools; e (e) comparação dos resultados dos modelos com base nas imagens-fração e nos valores de erro médio quadrático (RMSE). Os resultados obtidos mostraram que: (1) o uso sequencial das técnicas MNF, PPI e Visualizador *n*-Dimensional pode constituir uma etapa inicial para identificar pixels candidatos a MRs, cuja seleção final pode ser feita com as métricas EAR, MASA e CoB. Usadas de forma combinada, essas métricas minimizam possíveis efeitos da baixa relação sinal-ruído do Hyperion; (2) os MRs selecionados representaram os principais componentes de cena como “água” (com clorofila, límpida e com sedimentos em suspensão), “vegetação verde” (pinus, eucalipto e gramíneas) e “solo” (dunas e campo seco); (3) Por utilizar número e tipo variáveis de MRs, o modelo MESMA produziu melhores resultados que o SMA. Quando aplicado sobre a imagem, sobre a amostra de validação e quando comparado com o SMA, o modelo MESMA de 4 componentes (Solo = dunas e campo Seco; vegetação verde = pinus, eucalipto e gramíneas; água = com Sedimentos em suspensão, sem Sedimentos e com clorofila; sombra) descreveu adequadamente a diversidade dos componentes de cena, incluindo materiais dentro de uma mesma classe (p.ex. pinus e eucalipto). O MESMA produziu menores valores de RMSE e uma maior quantidade de pixels modelados na cena (85% contra 55%) do que o SMA; (4) o VIPER mostrou-se uma ferramenta bastante eficaz para seleção dos MRs e geração dos modelos. Os resultados, como um todo, demonstraram o potencial da aplicação dos modelos MESMA com dados hiperespectrais do sensor Hyperion/EO-1, mesmo considerando a baixa relação sinal/ruído do instrumento, especialmente no infravermelho de ondas curtas (SWIR).

Palavras-chave: Sensoriamento Remoto Hiperespectral, Processamento de Imagens, Biblioteca Espectral, Classificação, Membros de Referência.

* Dissertação de Mestrado em Sensoriamento Remoto, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Curso de Pós-Graduação em Sensoriamento Remoto da Universidade Federal do Rio Grande do Sul. Porto Alegre/RS, (140p.), Setembro, 2008.

EVALUATION OF MESMA AND SMA MIXTURE MODELS APPLIED TO HYPERION/EO-1 HYPERSPECTRAL DATA ACQUIRED ON THE COASTAL PLAIN OF RIO GRANDE DO SUL*

Author: Rodrigo de Marsillac Linn
Advisor: Dr. Sílvia B. A. Rolim
Co-Advisor: Dr. Lênio Soares Galvão

ABSTRACT

The objective of this work was to evaluate the potential use of the Hyperion/Earth Observing One (EO-1) hyperspectral data and of the MESMA (*Multiple Endmember Spectral Mixture Analysis*) and SMA (*Spectral Mixture Analysis*) mixture models to discriminate land covers in the Rio Grande do Sul state, South Brazil. MESMA differs from SMA because it may use a variable number and type of endmembers in each pixel. The methodology involved: (a) pre-processing of Hyperion data and conversion of radiance values into atmospherically corrected surface reflectance images; (b) sequential use of the Minimum Noise Fraction (MNF), Pixel Purity Index (PPI) and *n*-Dimensional Visualizer techniques, in the 454-2334 nm range, for initial selection of a general group of candidate endmembers (first spectral library) and of another group of pixels used for model validation; (c) use of VIPER (*Visualization and Image Processing for Environmental Research*) Tools algorithm for final selection of endmembers from the first spectral library and from the use of the metrics EAR (*Endmember Average RMSE*), MASA (*Minimum Average Spectral Angle*) and CoB (*Count Based Endmember Selection*); (d) use of VIPER tools to obtain MESMA and SMA models; and (e) comparison of modeling results based on the inspection of fraction images and root mean square error (RMSE) values. Results showed that: (1) the sequential use of the MNF, PPI and *n*-D Visualizer techniques may comprise an initial step to identify candidate endmembers. Final selection was performed using a combination of EAR, MASA and CoB to minimize possible effects of low signal-noise ratio (SNR) of Hyperion; (2) the selected endmembers represented major scene components such as water (with chlorophyll, clear or bearing in suspended sediments), green vegetation (pinus, eucalyptus and grasslands) and soil (dunes and dry grasslands); (3) By using a variable number and type of endmembers, MESMA produced better results than SMA. When applied over the image, the validation dataset and compared with SMA, the four-endmember MESMA model (soil = dunes and dry grasslands; green vegetation = pinus, eucalyptus and grasslands; water = with chlorophyll, clear and with suspended sediments; shadow) described adequately the diversity of the scene components, including materials within the same class (e.g., pinus and eucalyptus). MESMA produced lower RMSE values and greater number of modeled pixels (85% versus 55%) than SMA; (5) the VIPER tools seems to be an interesting approach for endmember selection and spectral mixture model generation. Results, as a whole, demonstrated the potential use of the MESMA with Hyperion/EO-1 hyperspectral data, even considering the low SNR of the instrument, especially in the shortwave infrared (SWIR).

Key Words: Hyperspectral Remote Sensing, Image Processing, Spectral Library, Classification, Endmembers.

* Master of Sciences Dissertation in Remote Sensing, Center for Remote Sensing and Meteorology, Graduate Program in Remote Sensing at Federal University of Rio Grande do Sul. Porto Alegre/RS, (140 p.), September, 2008.

SUMÁRIO

RESUMO	III
ABSTRACT	IV
LISTA DE FIGURAS.....	VII
LISTA DE TABELAS	XI
LISTA DE SIGLAS E ABREVIATURAS	XII
CAPÍTULO 1 - INTRODUÇÃO	1
CAPÍTULO 2 - FUNDAMENTAÇÃO TEÓRICA.....	4
2.1 - COMPORTAMENTO ESPECTRAL DE ALVOS	4
2.1.1 - Resposta Espectral do Solo	5
2.1.2 - Resposta Espectral da Vegetação	7
2.1.3 - Resposta Espectral da Água	10
2.2 – SENSORIAMENTO REMOTO HIPERESPECTRAL.....	15
2.2.1 – Conceito.....	15
2.2.2 – Histórico satélite EO-1.....	18
2.2.3 – Órbita do satélite EO-1.....	19
2.2.4 – Orientação dos sensores.....	20
2.2.5 – Ângulo de visada EO-1	20
2.2.6 – Sensor Hiperespectral Hyperion – EO-1.....	21
2.2.7 – Correção Nível 1R (USGS).....	23
2.2.8 – Relação Sinal-Ruído (SNR).....	25
2.2.9 – Aplicações.....	26
2.3 – PRÉ-PROCESSAMENTO DE IMAGENS HYPERION	27
2.3.1 – Destriping	27
2.3.2 – Correção efeito Smile	29
2.3.3 – Correção Atmosférica	30
2.3.4 – Correção Geométrica	33
2.4 - MODELO LINEAR DE MISTURA ESPECTRAL	34
2.4.1 - Mistura Espectral.....	34
2.4.2 – Algoritmo do modelo de Análise de Mistura Espectral (SMA).....	35
2.4.3 – Modelo de Análise de Mistura Espectral com Múltiplos Membros de Referência (MESMA)	37
2.4.4 - Seleção de Pixels Candidatos a Membros de Referência	38
2.4.4.1 – Transformação MNF (Minimum Noise Fraction)	41
2.4.4.2 - Índice de Pureza de Pixel (PPI).....	43
2.4.4.3 – Visualizador <i>n</i> -Dimensional	43
2.5 – SOFTWARE VIPER (VISUALIZATION AND IMAGE PROCESSING FOR ENVIRONMENTAL RESEARCH) TOOLS.....	44
2.5.1 – Biblioteca espectral	45
2.5.2 - Imagens Square Array (RMSE, SAM, EM Fraction, Shade Fraction e Constraint Code)	47
2.5.3 - Métricas EAR, MASA e CoB.....	49
2.5.3.1 - EAR (Endmember Average RMSE).....	50
2.5.3.2 - MASA (Minimum Average Spectral Angle)	51
2.5.3.3 - CoB (Count Based Endmember Selection)	52
2.5.3.4 – Cálculo das métricas EAR, MASA, CoB e seleção dos MRs com melhor desempenho.....	53
2.5.4 - MESMA/SMA	54
2.5.5 - Imagens fração (EM Fraction, Shade Fraction, RMSE e Modelo).....	56
CAPÍTULO 3 - ÁREA DE ESTUDO.....	58
3.1 - ASPECTOS GEOMORFOLÓGICOS	59
3.2 - ASPECTOS GEOLÓGICOS.....	61
3.3 - SOLO	63

3.4 - VEGETAÇÃO	64
3.5 - CLIMA	65
CAPÍTULO 4 - MATERIAIS E MÉTODOS	67
4.1 - SELEÇÃO DA ÁREA DE ESTUDO E AQUISIÇÃO DA IMAGEM HYPERION.....	69
4.2 – LEVANTAMENTO DE CAMPO	70
4.3 - PRÉ-PROCESSAMENTO DOS DADOS HYPERION.....	71
4.3.1 - <i>Correção dos Stripes e Efeito Smile</i>	71
4.3.2 – <i>Exclusão de Bandas</i>	73
4.3.3 – <i>Correção Atmosférica</i>	73
4.3.4 – <i>Correção Geométrica</i>	74
4.4 – PRIMEIRA BIBLIOTECA ESPECTRAL E AMOSTRAS DE VALIDAÇÃO A PARTIR DOS DADOS HYPERION	76
4.4.1 - <i>Transformação Minimum Noise Fraction (MNF) – Inversa</i>	77
4.4.2 - <i>Índice de Pureza do Pixel (PPI)</i>	77
4.4.3 - <i>Visualização n-Dimensional</i>	78
4.4.4 - <i>Seleção dos Candidatos a MRs, Amostras de Validação e Obtenção da 1ª Biblioteca Espectral</i>	78
4.5 – SELEÇÃO DOS MRS E GERAÇÃO DA 2ª BIBLIOTECA ESPECTRAL	79
4.5.1 - <i>Geração das Imagens Square Arrays (RMSE, SAM, EM Fraction, Shade Fraction e Constraint Code)</i>	79
4.5.2 – <i>Avaliação das Métricas EAR, MASA e CoB</i>	79
4.5.3 – <i>Geração da 2ª Biblioteca Espectral utilizando as Métricas EAR, MASA e CoB</i>	80
4.6 – MODELOS DE MISTURA	81
4.6.1 – <i>Determinação do Modelo MESMA mais Adequado segundo os Critérios de Fração e RMSE</i>	81
4.6.2 - <i>Geração das Imagens-fração e Imagem Classificada</i>	81
4.6.3 - <i>Geração do Modelo SMA</i>	82
4.7 - COMPARAÇÃO DOS MODELOS E AVALIAÇÃO DA ACURÁCIA	83
CAPÍTULO 5 - RESULTADOS E DISCUSSÃO	85
5.1 – COMPONENTES DE CENA.....	85
5.2 – PRÉ-PROCESSAMENTO	88
5.3 – PRIMEIRA BIBLIOTECA ESPECTRAL E AMOSTRAS DE VALIDAÇÃO A PARTIR DOS DADOS HYPERION	90
5.3.1 - <i>Transformação Minimum Noise Fraction (MNF) – Inversa</i>	90
5.3.2 - <i>Índice de Pureza do Pixel (PPI) e Visualizador</i>	91
5.3.3 – <i>Geração da 1ª Biblioteca Espectral através do VIPER Tools</i>	95
5.4 - GERAÇÃO DA 2ª BIBLIOTECA ESPECTRAL (VIPER TOOLS)	96
5.4.1 – <i>Imagens Square Array (RMSE, SAM, EM Fraction, Shade Fraction e Constraint Code)</i>	96
5.4.2 – <i>Avaliação das métricas EAR, MASA e CoB</i>	101
5.4.3 – <i>Seleção dos MRs através das Métricas (EAR, MASA e CoB) para Geração da 2ª Biblioteca Espectral</i>	103
5.5 – MODELOS DE MISTURA MESMA E SMA	105
5.5.1 – <i>Determinação do Modelo MESMA mais Adequado segundo os Critérios de Fração e RMSE</i>	105
5.5.2 - <i>Modelos MESMA</i>	106
5.5.3 - <i>Modelos SMA</i>	113
5.6 - ANÁLISE COMPARATIVA DOS RESULTADOS OBTIDOS PELOS MODELOS MESMA E SMA QUANTO AO CRITÉRIO DE FRAÇÃO E RMSE	115
CAPÍTULO 6 - CONCLUSÕES E SUGESTÕES	119
REFERÊNCIAS BIBLIOGRÁFICAS.....	123
APÊNDICE A - BANDAS ESPECTRAIS DO SENSOR HYPERION.....	135
APÊNDICE B - PONTOS COLETADOS EM CAMPO.....	138
APÊNDICE C - ROTINA MATLAB.....	139

LISTA DE FIGURAS

FIGURA 2.1 – Curvas de reflectância espectral típica de solo, vegetação e água.	4
FIGURA 2.2 – Curvas espectrais de solos contendo diferentes porcentagens de H ₂ O.	6
FIGURA 2.3 – Seção transversal de uma folha.....	8
FIGURA 2.4 – Fatores determinantes de reflectância da folha.....	9
FIGURA 2.5 – Reflectância de folhas de algodão superpostas.	10
FIGURA 2.6 – Absorção e espalhamento da luz na água límpida.	11
FIGURA 2.7 – Curvas de reflectância espectral medidas <i>in situ</i> da água límpida e da água com diferentes níveis de concentração de sedimento de solo argiloso em suspensão, variando no intervalo de 0 - 1.000 mg/l.....	12
FIGURA 2.8 – Percentual de reflectância da água límpida e da água com clorofila medida <i>in situ</i>	13
FIGURA 2.9 – Percentual de reflectância da água com clorofila com diferentes concentrações de sedimentos em suspensão, variando no intervalo de 0 – 500 mg/l.	14
FIGURA 2.10 – Curvas de reflectância espectral da água obtidas nos rios Tietê, Piracicaba e no reservatório de Barra Bonita, Estado de São Paulo.	15
FIGURA 2.11 - Efeito da variação da resolução espectral sobre o espectro de reflectância da vegetação verde (curva verde), solo (azul) e vegetação seca (vermelho).	16
FIGURA 2.12 - Ilustração do conceito da Espectroscopia de Imageamento.	16
FIGURA 2.13 - Comparação da faixa de imageamento dos sensores ETM+, ALI, Hyperion e AC.	19
FIGURA 2.14 - Possibilidades de imageamento. Exemplo de possibilidade de programação para um alvo localizado na órbita 31 ponto 39.	20
FIGURA 2.15 - Sensor Hyperion.	23
FIGURA 2.16 - Relação sinal-ruído do sensor Hyperion.	26
FIGURA 2.17 – Pixels anômalos nas bandas 94 e 119.....	27
FIGURA 2.18 - Variação do centro do comprimento de onda (efeito <i>smile</i>) na região do VNIR e SWIR em dados Hyperion.	30
FIGURA 2.19 - Exemplo do efeito <i>Smile</i> em dados Hyperion. Da esquerda para direita: 1ª componente MNF do VNIR e 1ª componente MNF do SWIR.....	30
FIGURA 2.20 - Irradiação solar e absorção atmosférica causada por O ₃ , H ₂ O, O ₂ CO ₂ e CH ₄	31
FIGURA 2.21 - Mistura espectral causada pela variedade de materiais no pixel.....	35
FIGURA 2.22 - Desempenho dos modelos de mistura SMA utilizando MRs selecionados pelo processo semi-automático e manual.....	40
FIGURA 2.23 - Exemplos de autovalores observados pela transformação MNF para dados SWIR dos sensores Hyperion e AVIRIS, adquiridos em Death Valley, CA.	42
FIGURA 2.24 - Exemplos de bandas MNF transformadas de dados SWIR do AVIRIS em Death Valley, CA. As bandas dispostas no sentido da esquerda para direita correspondem à seguinte ordem MNF: 1; 5; 8; 10 e 20.....	42
FIGURA 2.25 - Exemplos de bandas MNF transformadas de dados SWIR do Hyperion em Death Valley, CA.	43
FIGURA 2.26 - Visualizador <i>n</i> -Dimensional (ENVI).	44
FIGURA 2.27 - Janela com os menus de ferramentas implementadas no VIPER Tools.	45

FIGURA 2.28 - Janela para seleção dos ROIs para gerar a biblioteca espectral (<i>VIPER Tools</i>). 46	46
FIGURA 2.29 - Arquivo .csv metadados (Excel),46	46
FIGURA 2.30 - Imagens <i>Square Array</i>47	47
FIGURA 2.31 – Exemplo de uma imagem de saída <i>Constraint-Code</i>49	49
FIGURA 2.32 - Janela do <i>VIPER Tools (Create Square Array)</i> com os parâmetros de restrição de fração e RMSE.....49	49
FIGURA 2.33 - Membro de Referência A e o espectro modelado B, representados como vetores com componentes de reflexão de duas bandas espectrais..52	52
FIGURA 2.34 - Interface do <i>VIPER Tools (Calculate EAR/MASA/CoB)</i> para o cálculo das métricas EAR, MASA e CoB.53	53
FIGURA 2.35 - Interface do <i>VIPER Tools (EAR/MASA/COB Viewer)</i> para seleção dos MRs com melhor desempenho.....54	54
FIGURA 2.36 - Módulo <i>Run SMA/MESMA</i> do <i>VIPER Tools</i> para aplicação dos modelos de mistura SMA e MESMA.....55	55
FIGURA 2.37 - Exemplo de imagens fração resultante de um modelo com quatro MRs (GV+NPV+Solo+Sombra).....57	57
FIGURA 2.38 - Imagem fração sombra, RMSE e imagem residual da banda 19 (548 nm).57	57
FIGURA 2.39 - Imagem classificada - cada modelo (MESMA) é representado por uma cor; Composição RGB das imagens fração (NPV, GV, solo); imagem (AVIRIS) de entrada para o modelo.57	57
FIGURA 3.1 - Localização da área de estudo.58	58
FIGURA 3.2 – Perfil esquemático (W –E) transversal aos sistemas deposicionais da Planície Costeira do Rio Grande do Sul com suas fácies sedimentares associadas.60	60
FIGURA 3.3 – Mapa de situação da Província Costeira do Rio Grande do Sul e áreas adjacentes..61	61
FIGURA 4.1 - Metodologia de trabalho.68	68
FIGURA 4.2 - Seleção para aquisição da imagem Hyperion em acervo utilizando o <i>USGS Global Visualization Viewer</i>70	70
FIGURA 4.3 - Reconhecimento dos alvos imageados com o auxílio do programa para navegação em tempo real <i>GPS Track Maker</i>71	71
FIGURA 4.4 - <i>Stripes</i> na banda 11 (454,63 nm).....72	72
FIGURA 4.5 - Módulo <i>Hyperion Tools</i> (Devin White, 2007).72	72
FIGURA 4.6 - Seleção dos pontos de controle utilizando imagem GeoCover como referência....75	75
FIGURA 4.7 - Fluxograma do processamento implementado no ENVI para seleção inicial de pixels candidatos a membros de referência.....77	77
FIGURA 4.8 - Metodologia para geração das imagens-fração para cada subclasse e da imagem classificada, implementada no MatLab.82	82
FIGURA 5.1 – Composição colorida verdadeira com as bandas posicionadas em 638 nm (vermelho), 546 nm (verde) e 465 nm (azul)..85	85
FIGURA 5.2 – Exemplos de componentes de cena identificados na área de estudo.....86	86
FIGURA 5.3 – Banda 11 (455 nm) do Hyperion (a) antes e (b) depois do <i>destriping</i> utilizando o módulo <i>Hyperion Tools</i>88	88
FIGURA 5.4 – Reflectância espectral de pixels de água, solo e vegetação verde após a correção atmosférica dos dados Hyperion.89	89
FIGURA 5.5 - Autovalores resultantes da aplicação da técnica MNF sobre as 143 bandas do VNIR e SWIR da imagem Hyperion.....90	90

FIGURA 5.6 - Transformação MNF aplicada sobre os valores de reflectância de superfície de 143 bandas do sensor Hyperion.....	90
FIGURA 5.7 – Curva espectral da vegetação antes e depois da transformação MNF inversa.....	91
FIGURA 5.8 – Candidatos a MRs indicados pela técnica PPI sobre as 9 primeiras bandas MNF.	92
FIGURA 5.9 – Projeção dos pixels candidatos a MRs, selecionados pela técnica PPI, no Visualizador <i>n</i> -Dimensional (espaço de atributos MNF 1, 2 e 3) para as três principais classes de cobertura (água, vegetação e solo).	94
FIGURA 5.10 - Projeção dos pixels selecionados para compor a primeira biblioteca espectral (Grupo 1) no Visualizador <i>n</i> -Dimensional (espaço de atributos MNF 1, 2 e 3) para as 8 subclasses de cobertura.	94
FIGURA 5.11 - Projeção dos pixels selecionados para compor a amostra de validação (Grupo 2) no Visualizador <i>n</i> -Dimensional (espaço de atributos MNF 1, 2 e 3) para as 8 subclasses de cobertura.	94
FIGURA 5.12 – Porções da cena Hyperion de onde foram extraídos os pixels selecionados da aplicação seqüencial das técnicas MNF e PPI para compor o Grupo 1 (candidatos a MRs) e Grupo 2 (Amostra de Validação), envolvendo oito subclasses de cobertura.	95
FIGURA 5.13 – Arquivo metadado .csv gerado pelo módulo <i>Create Metadata for Spectral Library</i> e posteriormente editado no Excel para inclusão das respectivas classes e subclasses.	96
FIGURA 5.14 – Imagem <i>Square Array</i> RMSE– erro RMS produzido pelo espectro da coluna “y” para modelar o espectro da linha “x”.	97
FIGURA 5.15 – Média dos valores de brilho, referente às 8 subclasses da 1ª biblioteca espectral.	98
FIGURA 5.16 – Imagem <i>Square Array</i> - SAM – distância angular, medida em radianos, formada entre o espectro da coluna (eixo y) (espectro de referência) e o espectro da linha (eixo x).	98
FIGURA 5.17 – Imagem <i>Square Array</i> - Fração MR e Fração Sombra – corresponde à fração SMA utilizada pelo espectro da coluna (eixo y) para modelar o espectro da linha (eixo x)..	99
FIGURA 5.18 – Imagem <i>Constraint Code</i> – “1” indica se o modelo foi parcialmente restrito (as frações modeladas excederam o limite, mas não excederam o RMSE estipulado); “2” se o RMSE foi excedido (completamente restrito); e “0” (zero) para modelos sem qualquer restrição.	100
FIGURA 5.19 – Valores de RMSE resultantes do uso do MESMA utilizando separadamente os MRs selecionados pelas métricas EAR, MASA e CoB e uma amostra-teste aleatória de 160 pixels.	101
FIGURA 5.20 – Variação dos valores de RMSE em cada subclasse (20 pixels) resultante da aplicação do modelo MESMA utilizando separadamente os MRs selecionados pelas métricas EAR, MASA e CoB.	102
FIGURA 5.21 – Espectros de reflectância ($\times 10^4$) dos MRs selecionados a partir do uso das métricas EAR, MASA e CoB para gerar a segunda biblioteca espectral..	104
FIGURA 5.22 – Imagens fração geradas pelo VIPER <i>Tools</i> para cada componente do modelo MESMA.	107
FIGURA 5.23 – Imagem fração Sombra de porção da cena, indicando pixels da classe Água com Sedimento modelados com alta fração de sombra (aproximadamente 70%).....	108
FIGURA 5.24 – a) Imagem RMSE; e (b) composição colorida fração Solo (vermelho), fração vegetação (verde) e fração água (azul)..	109

FIGURA 5.25 – Imagens Fração das 8 subclasses: (a) Água com Clorofila; (b) Água com Sedimento; (c) Água sem Sedimento; (d) Campo Seco; (e) Dunas; (f) Eucalipto; (g) Gramíneas; e (h) Pinus.	110
FIGURA 5.26 – Resultado obtido pelo modelo MESMA com 4 componentes. Imagem classificada a partir da componente com maior fração.	112
FIGURA 5.27 – Resultado obtido pelo MESMA sobre parte da área urbana do Município de Tramandaí.	113
FIGURA 5.28 – Classificações SMA com base no MR de maior fração no pixel para os modelos (a) 107 com 13,92 % da imagem classificada e (b) 129 com 55.21% da imagem classificada.	115
FIGURA 5.29 – Comparação entre as classificações resultantes da fração dominante do MR para os modelos (a) SMA 129 e (b) MESMA.	118

LISTA DE TABELAS

TABELA 2.1 – Características principais das curvas espectrais de solos.	6
TABELA 2.2 – Exemplos de sensores hiperespectrais orbitais e aerotransportados, operacionais e planejados para lançamento.	18
TABELA 2.3 - Característica dos sensores do EO-1.	19
TABELA 2.4 - Variação do ângulo de visada para latitudes específicas.	21
TABELA 2.5 - Principais características do sensor Hyperion.	22
TABELA 2.6 - Bandas calibradas vs. não calibradas.	23
TABELA 2.7 – Localização dos <i>stripes</i> nos dados Hyperion.	28
TABELA 4.1 - Características da imagem Hyperion adquirida.	69
TABELA 4.2 - Bandas Hyperion excluídas dos dados originais do produto L1R.	73
TABELA 4.3 - Parâmetros utilizados para correção atmosférica no FLAASH.	74
TABELA 4.4 - Parâmetros adotados no módulo “ <i>Create Square Array</i> ” (VIPER Tools) para o cálculo das métricas de ajuste.	79
TABELA 4.5 - Parâmetros utilizados para aplicação do MESMA (Roberts et al., 1998; Dennison & Roberts, 2003).	81
TABELA 5.1 – Pontos de controle utilizados para o registro da imagem Hyperion.	89
TABELA 5.2 – Autovalores e percentual de variância correspondente às 15 primeiras bandas MNF.	91
TABELA 5.3 - Classes, subclasses e número de pixels selecionados para compor o Grupo 1 (candidatos a MRs) e Grupo 2 (Amostra de Validação), resultante da aplicação sequencial das técnicas MNF e PPI.	93
TABELA 5.4 – Pixels selecionados (23 candidatos a MRs), com base nas métricas EAR, MASA e CoB (EMC), para compor a segunda biblioteca espectral.	103
TABELA 5.5 – Número de modelos MESMA gerados a partir da 2ª biblioteca espectral para avaliação do desempenho.	105
TABELA 5.6 – Resultado obtido pelos modelos MESMA de 2, 3 e 4 componentes (MRs) sobre a amostra de validação.	106
TABELA 5.7 – Resultado obtido pelo modelo MESMA com 4 componentes sobre a amostra de validação.	106
TABELA 5.8 – Modelos SMA selecionados a partir dos modelos MESMA de melhor desempenho.	113
TABELA 5.9 – Percentual de pixels modelados sobre a amostra de validação e imagem pelos oito modelos SMA da Tabela 5.7.	114
TABELA 5.10 – Valores de RMSE e de fração resultantes dos modelos MESMA e SMA aplicados na modelagem do conjunto de pixels da amostra de validação.	117

LISTA DE SIGLAS E ABREVIATURAS

ACORN	<i>Atmospheric CORrection Now</i>
AIS	<i>Airborne Imaging Spectrometer</i>
ALI	<i>Advanced Land Imager</i>
APC	<i>Análise por Principais Componentes</i>
ATREM	<i>ATmosphere REMoval program</i>
AVIRIS	<i>Airborne Visible/InfraRed Imaging Spectrometer</i>
COAs	<i>Constituintes Opticamente Ativos</i>
CoB	<i>Count-based Endmember Selection</i>
CoBI	<i>Count Based Index</i>
CRES	<i>Constrained Reference Endmember Selection</i>
CSV	<i>Comma Separated Value</i>
CWL	<i>Spectral Center Wavelengths</i>
EAR	<i>Endmember Average RMSE</i>
ENVI	<i>ENvironment for Visualizing Images</i>
EO-1	<i>Earth Observing-1</i>
ESA	<i>European Space Agency</i>
ETM+	<i>Enhanced Thematic Mapper</i>
EVF	<i>ENVI Vector Files</i>
FLAASH	<i>Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes</i>
FRB	<i>Fator de Reflectância Bidirecional</i>
FTP	<i>File Transfer Protocol</i>
FWHM	<i>Full Width Half Max</i>
GeoTIFF	<i>Geographic Tagged Image-File Format</i>
GPS	<i>Global Positioning System</i>
GV	<i>Green Vegetation</i>
HATCH	<i>High Accuracy Atmospheric Correction for Hyperspectral Data</i>
HDF	<i>Hierarchical Data Format</i>
HSI	<i>Hyperspectral Imaging Instrument</i>
ICC	<i>Intraclass Correlation Coefficient</i>
IDL	<i>Interactive Data Language</i>
IFOV	<i>Instantaneous Field of View</i>
JPL	<i>Jet Propulsion Laboratory</i>

LAC	<i>LEISA Atmospheric Corrector</i>
MASA	<i>Minimum Average Spectral Angle</i>
MATLAB	<i>MATrix LABoratory</i>
MESMA	<i>Multiple Endmember Spectral Mixture Analysis</i>
MNF	<i>Minimum Noise Fraction</i>
MODTRAN	<i>MODerate resolution atmospheric radiance and TRANsmittance Model</i>
MR	Membro de Referência
MSS	<i>Multie Spectral Scanner</i>
NASA	<i>National Aeronautics and Space Administration</i>
ND	Número Digital
NE	Nordeste
NMP	<i>New Millennium Program</i>
NPV	<i>Nonphotosynthetic Vegetation</i>
PPI	<i>Pixel Purity Index</i>
RMS	<i>Root Mean Square</i>
RMSE	<i>Root Mean Square Error</i>
ROI	<i>Region of Interest</i>
SAM	<i>Spectral Angle Mapper</i>
SMA	<i>Spectral Mixture Analysis</i>
SW	Sudoeste
SWIR	<i>Short Wave Infrared</i>
TM	<i>Thematic Mapper</i>
UFRGS	Universidade Federal do Rio Grande do Sul
USGS	<i>United States Geological Survey</i>
VIPER	<i>Visualization and Image Processing for Environmental Research</i>
VNIR	<i>Visible and Near infrared</i>
WRS-2	<i>World Reference System-2</i>

CAPÍTULO 1

INTRODUÇÃO

Cada vez mais, dados obtidos por sensores remotos orbitais têm sido utilizados para identificar e quantificar, através de técnicas de classificação digital, os materiais presentes na superfície terrestre, gerando como produtos, mapas temáticos de uso e cobertura do solo (Tisot et al., 2005). Geralmente, utilizam-se para estes estudos, sensores multiespectrais como, por exemplo, o Landsat 7/ *Enhanced Thematic Mapper* (ETM+), com 8 bandas espectrais. No entanto, estes sensores não permitem um estudo mais detalhado sobre o comportamento espectral dos alvos.

Na década de 80, avanços tecnológicos conduziram ao desenvolvimento de uma nova etapa de coleta de dados: a do sensoriamento remoto hiperespectral, também conhecido como Espectroscopia de Imageamento (Green et al., 1998). Essa etapa consiste na aquisição simultânea de imagens em centenas de bandas estreitas e contíguas (Goetz et al., 1985), de forma que o espectro de reflectância de um pixel possa ser medido em condições de resolução espectral mais próximas das existentes em laboratório.

Em 21 de novembro de 2000, foi lançado, a bordo do satélite *Earth Observing-1* (EO-1) da *National Aeronautics and Space Administration* (NASA), o sensor Hyperion, o primeiro sensor hiperespectral a operar em órbita terrestre. Com 242 bandas espectrais, posicionadas entre 0,4 e 2,5 μm (Goodenough et al., 2002), este sensor possibilita a extração de um espectro de reflectância detalhado – praticamente contínuo – para cada elemento de cena (pixel) da imagem.

Por outro lado, a resposta espectral de um pixel é, na realidade, uma soma integrada da resposta espectral dos componentes da cena “vistos” dentro do campo de visada do sensor (*Instantaneous Field of View* - IFOV) como, por exemplo, do solo, da vegetação, da água e da sombra que é projetada sobre o solo, além da contribuição atmosférica (Shimabukuro & Smith, 1991). Neste caso, o sucesso na identificação e mapeamento de um material contido em um pixel dependerá da contribuição proporcional de cada uma desses componentes para sua resposta espectral.

Para que se possa conhecer a proporção dos diferentes materiais presentes em um pixel, podem ser utilizados modelos que permitem a decomposição do pixel em seus componentes puros ou “Membros de Referência”. O modelo linear de mistura espectral (*Spectral Mixture Analysis – SMA*) (Smith et al., 1985) é uma ferramenta de processamento digital de imagens que permite separar as proporções relativas de cada objeto dentro de um pixel, a partir de um conjunto de componentes puros da imagem (Pereira et al., 1998).

A SMA baseia-se no emprego da regressão múltipla para quantificar a proporção dos materiais presentes na imagem. Esse procedimento teve sua origem no processamento de imagens multiespectrais (Roberts et al., 1993; Shimabukuro & Smith, 1991; Adams & Smith, 1986; Smith et al., 1985), obtendo grande propagação em estudos astronômicos com propósito de definir a composição superficial de astros (Smith et al., 1985). No entanto, a SMA falha por considerar todos os pixels como mistura linear de um único conjunto inicial de membros de referência (MRs). Desta forma, pode-se ter um pixel modelado por MRs que nele sejam inexistentes (Carvalho Júnior et al., 2003). Por exemplo, considerando-se uma cena descrita pelos MRs “vegetação”, “solo” e “sombra”, o cálculo da mistura será realizado com base nos três elementos, mesmo que não haja um dos componentes para o pixel.

Para corrigir essa fonte de erro foi proposto um novo método que estabelece para cada pixel o melhor modelo de mistura e assim realiza o cálculo de abundância dos MRs (Smith et al. 1992, Sabol et al. 1992b, Roberts et al. 1992). A evolução dessa proposta deu origem ao modelo de Análise de Mistura Espectral com Múltiplos Membros de Referência (*Multiple Endmember Spectral Mixture Analysis - MESMA*) (Roberts et al. 1998a). O MESMA difere do SMA por permitir que o número e o tipo de MRs, assim como sua abundância, variem de pixel para pixel.

Com o intuito de criar uma ferramenta amigável para aplicação do MESMA, Roberts et al. (2007) desenvolveram o Programa VIPER (*Visualization and Image Processing for Environmental Research*) Tools, de distribuição gratuita. Este programa possui ainda um conjunto de ferramentas para auxiliar na geração e edição de bibliotecas espectrais, na criação de arquivos metadados e principalmente, para

auxiliar na seleção dos MRs mais representativos para serem empregados nos modelos MESMA/SMA.

Neste contexto, o objetivo do presente trabalho é avaliar o potencial dos dados hiperspectrais do sensor orbital Hyperion e do modelo MESMA na discriminação de classes de cobertura do Litoral Norte do Estado do Rio Grande do Sul.

De forma mais específica, os seguintes objetivos foram definidos:

- a) Avaliar técnicas de processamento digital aplicadas aos dados Hyperion para seleção de MRs;
- b) Avaliar quantitativamente e qualitativamente se, efetivamente, o modelo MESMA produz melhores resultados que o modelo SMA; e,
- c) Testar o Programa VIPER *Tools* na aplicação dos modelos SMA e MESMA e na seleção de MRs.

CAPÍTULO 2

FUNDAMENTAÇÃO TEÓRICA

2.1 - Comportamento espectral de alvos

Cada objeto na natureza reflete, absorve e transmite a radiação eletromagnética em proporções que variam em função das suas propriedades físico-químicas e biológicas. Portanto, cada objeto tem um comportamento espectral distinto, o qual é determinado quando sua energia refletida é medida ao longo do espectro eletromagnético.

A variação da energia refletida pelos objetos pode ser representada por meio de curvas de reflectância espectral, que expressam o comportamento espectral de cada alvo (Figura 2.1). Assim, por exemplo, uma área de floresta apresenta uma curva espectral diferente de uma urbana, de um corpo d'água ou de uma área agrícola. Esta diferença na radiação refletida pelos objetos faz com que seja possível identificá-los e diferenciá-los nas imagens obtidas por sensores remotos, pois são reconhecidos devido à variação da porcentagem de energia refletida em cada comprimento de onda.




FIGURA 2.1 – Curvas de reflectância espectral típica de solo, vegetação e água.
FONTE: Adaptada de Lillesand et. al. (2004).

Deve-se salientar que estas curvas podem sofrer consideráveis alterações, principalmente quando adquiridas por sensores orbitais, visto que estão sujeitos a

interferências de fatores externos (atmosfera) e internos (ruído do sensor). Assim, para que se conheça a fundo o comportamento espectral de um determinado alvo, faz-se necessário um estudo detalhado da resposta deste alvo em diversas condições, além do estudo de suas propriedades bio-físico-químicas. Apesar destas possíveis variações de respostas, é comum que se encontre na literatura curvas “padrão” ou “típica” que representem, de forma genérica, a resposta espectral da reflectância de alvos também tomados como genéricos, por exemplo, “vegetação”, “solo” e “água”. As curvas típicas são importantes para mostrar os pontos fundamentais a serem estudados nas propriedades de reflectância de um determinado alvo.

A seguir será apresentada uma breve discussão sobre os principais aspectos da reflectância dos três alvos naturais que serão explorados neste trabalho: vegetação, solo e água.

2.1.1 - Resposta Espectral do Solo

A resposta espectral do solo tem como característica mais marcante os valores crescentes de reflectância com o aumento do comprimento de onda. Como apresentam diferentes constituintes, podem ser identificados e em certos casos quantificados em proporção pela análise de sua resposta espectral. Os principais constituintes dos solos que influenciam seu comportamento espectral são: a matéria orgânica, óxidos de ferro e argilominerais, além da distribuição granulométrica e umidade.

Segundo Lillesand et al. (2004), a curva de solo apresenta poucas bandas de absorção, sendo três de absorção pela água em 1,4 μm , 1,9 μm e 2,7 μm (as mesmas da vegetação) e duas bandas de absorção por hidroxilas em 1,4 μm e 2,2 μm , presentes nos solos argilosos. Na porção do visível, o aumento da quantidade de água líquida (não presente na estrutura de minerais) causa uma diminuição na reflectância, que explica o fato dos solos escurecerem ao serem molhados (Figura 2.2). Nas regiões do infravermelho próximo e médio, a diminuição da reflectância com o aumento do conteúdo de água deve-se a alta absorção da radiação eletromagnética pela água nestes comprimentos de onda.




FIGURA 2.2 – Curvas espectrais de solos contendo diferentes porcentagens de H₂O.
 FONTE: Adaptada de Moreira (2003).

Conforme sugestões de Condit e Stoner & Baumgardner (1970, 1980, *apud* Novo, 1992), as curvas espectrais de solos podem ser classificadas em 5 tipos:

Tipo de Curva	Região do Espectro	Feição Espectral	Característica do Solo
1	0,32 - 1,0 µm	baixa reflectância forma côncava	
2	0,32 - 0,60 µm 0,60 - 0,70 µm 0,70 - 0,75 µm 0,32 - 0,75 µm	gradiente decrescente gradiente acentuado gradiente decrescente forma convexa	solos bem drenados pouca matéria orgânica
3	0,32 - 0,60 µm 0,60 - 0,74 µm 0,76 - 0,78 µm 0,88 - 1,00 µm	gradiente acentuado gradiente pequeno gradiente decrescente gradiente aumenta	solos com conteúdo de ferro razoavelmente elevado
4	0,32 - 2,3 µm 0,88 - 1,3 µm	baixa reflectância redução da reflectância	alto conteúdo de ferro e matéria orgânica
5	0,75 - 1,3 µm	gradiente decrescente não há banda de absorção de água em 1,45 µm	alto conteúdo de ferro e baixo conteúdo de matéria orgânica

TABELA 2.1 – Características principais das curvas espectrais de solos.
 FONTE: Adaptada de Novo (1992).

A classificação mostrada na Tabela 2.1 foi obtida com amostras na condição úmida e, portanto, sua associação com as características físico-químicas do solo deve ser feita com cuidado.

2.1.2 - Resposta Espectral da Vegetação

A curva espectral da vegetação – no caso da vegetação verde sadia - se caracteriza pela intensa absorção da radiação eletromagnética nas regiões do azul e do vermelho (devido à clorofila) e pela intensa reflexão na faixa do infravermelho (IV) próximo (causada pela estrutura foliar).

A folha é o principal elemento a ser estudado no processo de interação da energia eletromagnética com a vegetação. O comportamento espectral de uma folha é função de sua composição, morfologia e estrutura interna.

Segundo Gates et al. (1965, *apud* Moreira, 2003), são três os principais fatores que influenciam a quantidade de energia eletromagnética refletida pelas folhas: pigmentos, espaços ocupados pela água e pelo ar e estruturas celulares com dimensões do comprimento de onda da radiação incidente (grãos de amido, mitocôndrias, ribossomos, núcleo e outros plastídios). Além desses três fatores, existem outros que afetam a energia refletida pelas folhas, como conteúdo de água, maturação ou idade da folha, posição nodal, condição de iluminação, pubescência e senescência.

Segundo Moreira (2003), uma pequena quantidade de luz é refletida pelas células da camada superficial; a maior parte é transmitida para o mesófilo esponjoso (Figura 2.3), onde os raios incidem freqüentemente nas paredes celulares, sendo refletidos se os ângulos de incidência da radiação forem suficientemente grandes. Dado o grande número de paredes celulares dentro da folha, alguns raios são refletidos de volta, na direção da fonte de energia incidente, enquanto outros são transmitidos através da folha.




FIGURA 2.3 – Seção transversal de uma folha.
 FONTE: Adaptada de Ponzoni & Shimabukuro (2007).

A radiação eletromagnética compreendida na faixa de comprimento de onda entre 400 e 3.000 nm, denominada espectro reflectivo, apresenta uma curva bastante característica, conforme mostrado na Figura 2.3. Este intervalo de comprimento de onda foi dividido por Ponzoni & Shimabukuro (incluir referências (2007) em três partes, descritas como:

a) Região do visível (0,4 – 0,72 μm): neste intervalo os pigmentos existentes nas folhas dominam a reflectância sendo, portanto, responsáveis pela forma da curva nessa região espectral. Estes pigmentos geralmente encontrados nos cloroplastos são: clorofila (65%), caroteno (6%) e xantofilas (29%). Os valores percentuais destes pigmentos existentes podem variar intensamente de espécie para espécie. A energia radiante interage com a estrutura foliar por absorção e por espalhamento. A energia é absorvida seletivamente pela clorofila e convertida em calor ou fluorescência, e também convertida fotoquimicamente em energia armazenada na forma de componentes orgânicos através de fotossíntese. Os pigmentos predominantes absorvem radiação na região do azul (próximo a 0,445 μm), mas somente a clorofila absorve na região do vermelho (0,645 μm). A maioria das plantas são moderadamente transparentes na região do verde (0,540 μm);

b) Região do infravermelho próximo (0,72 – 1,10 μm): Neste intervalo ocorre absorção pequena da radiação e considerável espalhamento interno da radiação da folha. A absorção da água é geralmente baixa, enquanto que a reflectância é quase constante;

c) Região do infravermelho médio (1,10 – 3,20 μm): A absorção devida à água líquida intrafoliar afeta a reflectância das folhas na região do infravermelho médio. Considerando a água líquida, esta apresenta na região em torno de 2,0 μm , fatores de reflectância geralmente pequenos. A água absorve consideravelmente a radiação incidente na região espectral compreendida entre 1,3 μm a 2,0 μm . Mais precisamente, nos comprimentos de onda de 1,45 μm , 1,95 μm e 2,7 μm , bandas de absorção podem ser observadas (Figura 2.4);

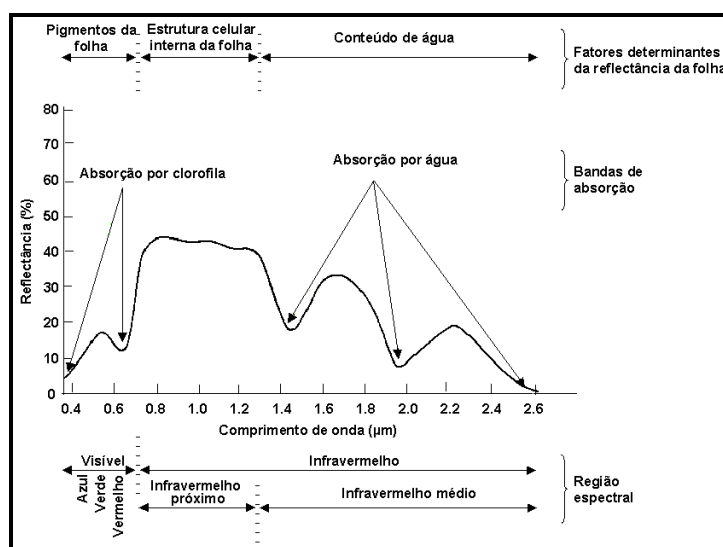


FIGURA 2.4 – Fatores determinantes de reflectância da folha.
 FONTE: Adaptada de Teixeira (2004).

O destino da radiação eletromagnética que incide num dossel vegetativo depende de suas características, como comprimento de onda e ângulo de incidência, além das características do dossel e, em última análise, das folhas que o compõe.

Em se tratando de culturas agrícolas, Richardson et al. (1975) e Kollenkark et al. (1982) comentaram que os dosséis de cultura exibem, no campo de visada do sensor, quatro componentes com diferentes propriedades de reflectância óptica: vegetação iluminada, solo iluminado, vegetação sombreada e solo sombreado. A magnitude de cada um desses componentes varia com a cobertura vegetal, orientação e espaçamento das fileiras, morfologia do dossel, estrutura interna dos elementos que compõem o dossel, diâmetro da copa da planta, altura, teor de água na planta e no solo, condição fitossanitária, ângulo zenital e azimutal do sol, latitude e tamanho do elemento de resolução do equipamento utilizado.

Também vale salientar que, na região do infravermelho próximo, a quantidade de radiação refletida por várias camadas de folhas, é bem maior do que a refletida por uma única folha (Figura 2.5). Isso ocorre devido ao fenômeno denominado de reflectância aditiva.

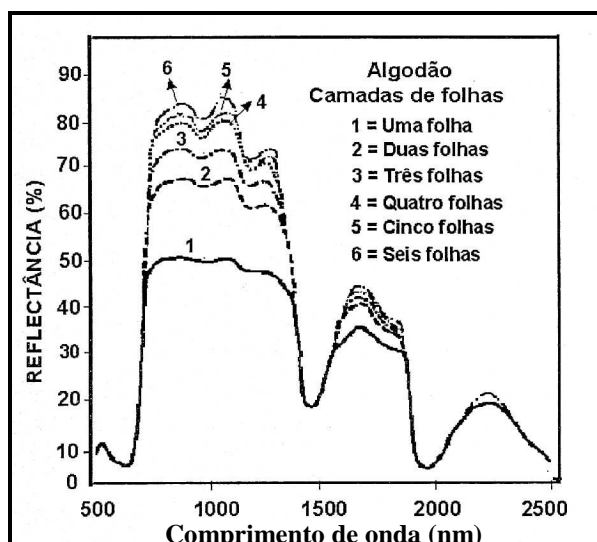


FIGURA 2.5 – Reflectância de folhas de algodão superpostas.
FONTE: Adaptada de Moreira (2003).

2.1.3 - Resposta Espectral da Água

O comportamento espectral da água está intensamente relacionado ao seu estado físico: sólido (e.g. neve), líquido e gasoso (e.g. nuvem), apresentando feições totalmente distintas para cada um deles. Neste estudo, será abordado apenas o comportamento espectral da água no estado líquido, que será descrito a seguir.

A água no estado líquido apresenta baixa reflectância na faixa compreendida entre 380 e 700 nm, absorvendo toda a radiação eletromagnética fora desse intervalo. Este fato demonstra que a água, no estado líquido, é um forte absorvedor da radiação na maior parte do espectro eletromagnético. Como pode ser observado na Figura 2.6, a menor absorção da radiação se dá na região do azul, no intervalo compreendido entre 400 e 500 nm, com o mínimo localizado no intervalo de 460 a 480 nm. Nessa região o espalhamento possui praticamente a mesma intensidade. Na região do verde e amarelo (520 – 580 nm) a radiação já é bastante absorvida pela água e com menor

espalhamento. Na região do laranja e vermelho (580 – 740 nm) a absorção é total e o espalhamento é insignificante (Jensen, 2000).

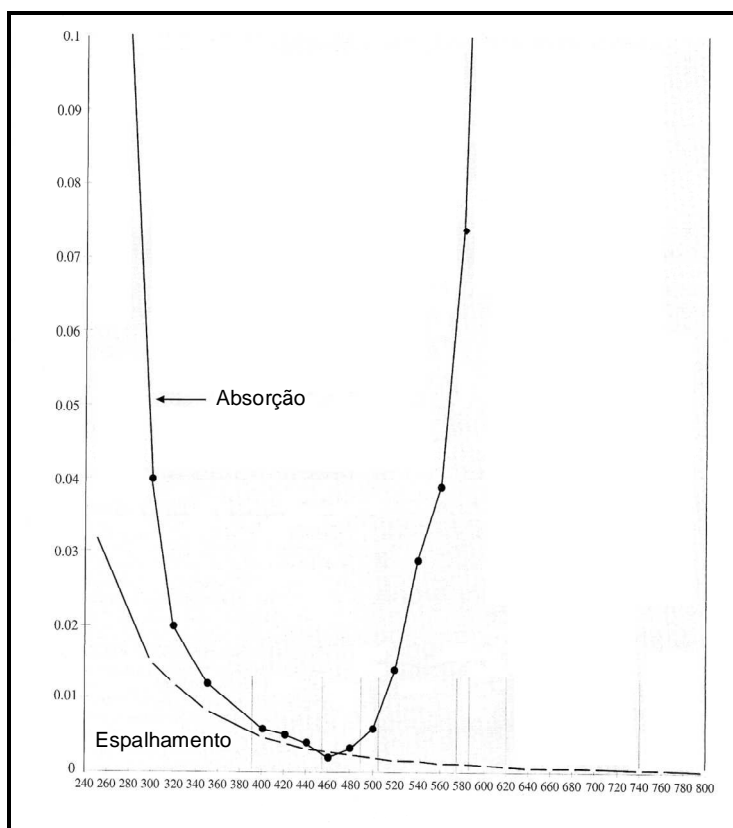


FIGURA 2.6 – Absorção e espalhamento da luz na água límpida.
FONTE: Adaptada de Jensen (2000).

Além do estado físico, o comportamento espectral da água é modulado principalmente pelos processos de absorção e espalhamento produzidos pelos Constituintes Opticamente Ativos (COAs), como: (a) sedimentos em suspensão, (b) pigmentos fotossintetizantes (fitoplânctons) e (c) substâncias húmicas (matéria orgânica).

Geralmente os corpos d'água apresentam a combinação de diversos COAs, ocorrendo em alguns casos a dominância de um determinado COA, o que possibilita identificar e compreender de que forma as feições existentes nos espectros de reflectância podem estar relacionadas a determinadas substâncias. A seguir será brevemente discutido como os três principais COAs tratados na literatura influenciam a variação da resposta espectral de corpos d'águas.

2.1.3.1 - Sedimentos em Suspensão

Os sedimentos em suspensão têm sua origem no intemperismo das rochas e solos, sendo o COA que mais afeta as propriedades óticas da água. Quando a concentração de sedimentos de solo em suspensão aumenta, o pico de reflectância se desloca em direção aos maiores comprimentos de onda, na região do visível (580 – 690 nm) e infravermelho próximo (Figura 2.7). Sedimentos de solos com textura argilosa possuem maior quantidade de matéria orgânica, sendo por esse motivo, mais escuros, o que resulta em aproximadamente 10 % a menos de reflectância do que sedimentos provenientes de solos siltsos.

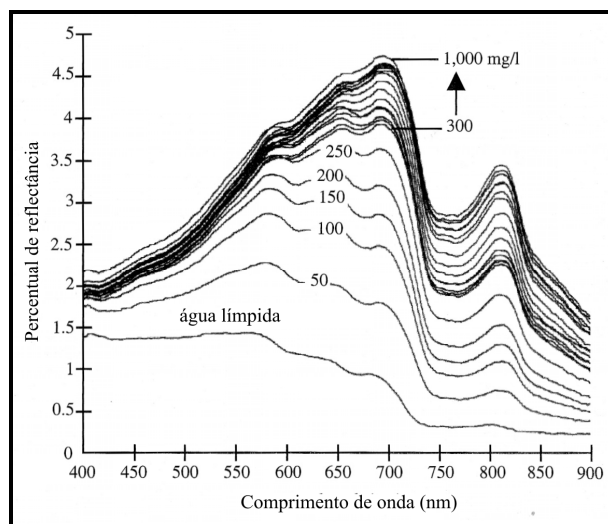


FIGURA 2.7 – Curvas de reflectância espectral medidas *in situ* da água límpida e da água com diferentes níveis de concentração de sedimento de solo argiloso em suspensão, variando no intervalo de 0 - 1.000 mg/l.

FONTE: Adaptada de Jensen (2000).

2.1.3.2 – Pigmentos Fotossintetizantes

Todos os fitoplânctons presentes em corpos d'água contém o pigmento fotossinteticamente ativo clorofila. Esse pigmento provoca algumas feições características de absorção e espalhamento (Figura 2.8), como:

- Forte absorção da radiação eletromagnética na região do azul (400 – 500 nm);

- Elevada absorção da radiação eletromagnética na região do vermelho, aproximadamente no comprimento de onda 675 nm;
- Reflectância máxima em torno de 550 nm (pico do verde) causada pela baixa absorção da luz verde;
- Pico de reflectância em torno de 690 – 700 nm, causado pelo espalhamento interno nas células do fitoplâncton.

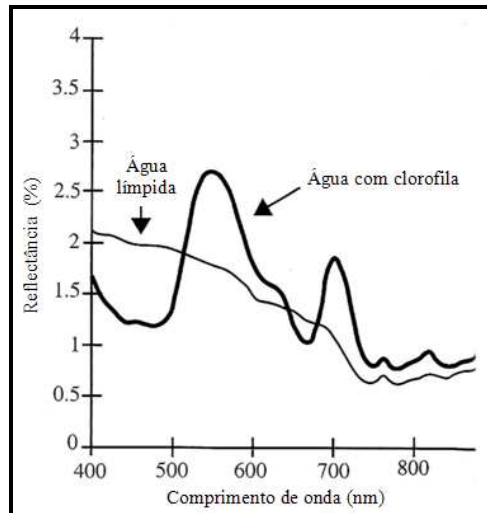


FIGURA 2.8 – Percentual de reflectância da água límpida e da água com clorofila medida *in situ*.

FONTE: Adaptada de Jensen (2000).

Quando água com sedimento e com água com clorofila estão presentes em um mesmo corpo d'água, a resposta espectral é consideravelmente alterada. Como pode ser observado na Figura 2.9, quando diferentes concentrações de água com sedimento são misturadas à água com clorofila, o pico de reflectância se desloca de 547 nm (verde) para 596 nm (laranja).

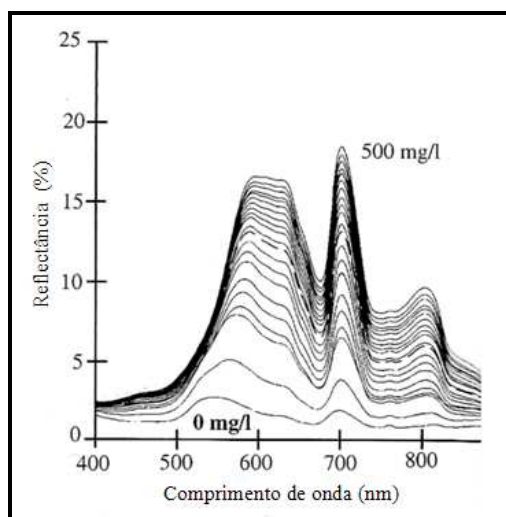


FIGURA 2.9 – Percentual de reflectância da água com clorofila com diferentes concentrações de sedimentos em suspensão, variando no intervalo de 0 – 500 mg/l.
 FONTE: Adaptada de Jensen (2000).

2.1.3.3 - Matéria Orgânica Dissolvida

As substâncias húmicas, freqüentemente, apresentam coloração amarelada e influenciam fortemente a absorção de luz na coluna d'água. Enquanto a água pura apresenta espalhamento mais intenso na faixa do azul, a presença de matéria orgânica dissolvida provoca absorção seletiva de radiação em comprimentos de onda menores, dentro da faixa do VIS. Este fato é notado em termos visuais, pois corpos d'água com elevada concentração de matéria orgânica dissolvida apresentam coloração mais escura e amarelada (Jensen, 2000).

Um exemplo bastante ilustrativo da influência da matéria orgânica e inorgânica no comportamento espectral da água pode ser visualizado na Figura 2.10 (Steffen et al., 1992). Neste estudo, a reflectância da água foi medida em três pontos distintos: a) no reservatório da Barra Bonita, formados pelos rios Piracicaba e Tietê, SP; b) no Rio Tietê; e c) no Rio Piracicaba. Os autores chegaram as seguintes conclusões:

- A reflectância no Rio Tietê é típica de água com elevada concentração de material inorgânico em suspensão, com acentuada reflectância na faixa do vermelho;

- A água do Rio Piracicaba apresenta uma reflectância bastante baixa, com pico de máxima reflectância na região do verde (aproximadamente 23%), sendo por esse motivo, forte indicador da presença de material orgânico em suspensão (e.g. clorofila);

- A reflectância da água, obtida no corpo central do reservatório de Barra Bonita, onde as águas dos dois rios já se encontram misturadas, mostra claramente a transição entre os dois espectros anteriores.

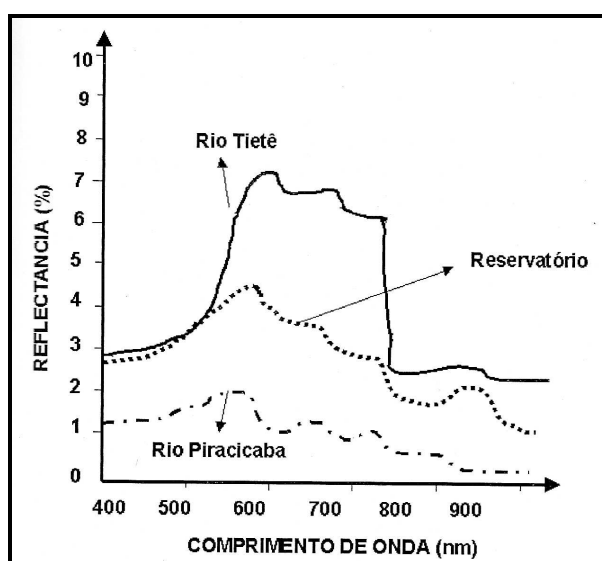


FIGURA 2.10 – Curvas de reflectância espectral da água obtidas nos rios Tietê, Piracicaba e no reservatório de Barra Bonita, Estado de São Paulo.
FONTE: Adaptada de Steffen (1992).

2.2 – Sensoriamento Remoto Hiperespectral

2.2.1 – Conceito

Até a década de 90, a obtenção de imagens da Terra por sensoriamento remoto foi dominada por experimentos com imageadores multiespectrais, como o Landsat *Multispectral Scanner* (MSS, 4 bandas) e Landsat Mapeador Temático (TM, 7 bandas). Estes sensores, além de conterem um número reduzido de bandas, possuem largura de banda entre 100 nm e 200 nm, sub-amostrando drasticamente o conteúdo informativo da reflectância dos materiais. Entretanto, uma nova geração de sensores foi desenvolvida, combinando imageamento com espectroscopia (Clark et al., 2006) (Figura 2.11).




FIGURA 2.11 - Efeito da variação da resolução espectral sobre o espectro de reflectância da vegetação verde (curva verde), solo (azul) e vegetação seca (vermelho): (a) Sensor hiperespectral Hyperion e (b) Sensor multiespectral ETM+.
 FONTE: Adaptada de Roberts (2007).

O sensoriamento remoto hiperespectral, também denominado Espectroscopia de Imageamento, consiste na aquisição simultânea de imagens em centenas de bandas estreitas (na ordem de 10 nm) contíguas, permitindo a extração de um espectro detalhado para cada elemento de cena (pixel) da imagem (Figura 2.12), com base em suas características de reflectância (Goetz et al., 1985).




FIGURA 2.12 - Ilustração do conceito da Espectroscopia de Imageamento.
 FONTE: Adaptada de Green et al. (1998).

Segundo Green et al. (1998), podemos definir um sensor como hiperespectral como aquele que permite a aquisição de imagens em mais de 50 bandas espectrais contíguas. A contigüidade, o número de bandas e a largura nominal de cada banda são

fundamentais para o conceito de sensoriamento remoto hiperespectral, pois a análise dos dados derivados desses sensores se baseia na identificação de feições de absorção presentes no espectro, para através delas determinar: o tipo de material presente, sua abundância, proporção e distribuição espacial.

Como a maior parte dos materiais presentes na superfície terrestre possui feições próprias de absorção na região de 0,4 a 2,5 μm do espectro eletromagnético, que variam de 20 a 40 nm de largura, é possível, em alguns casos, fazer uma identificação direta desses materiais na cena. É possível também determinar sua abundância, através da comparação dos espectros de reflectância dos pixels com espectros de referência medidos no campo e laboratório ou extraídos da própria imagem. Assim, foram realizados diversos estudos hiperespectrais com: (a) minerais (Goetz et al., 1985; Kruse et al., 1993a; Boardman & Kruse, 1994; Clark et al., 1996); (b) gases constituintes da atmosfera (Gao & Goetz, 1990; Carrère & Conel, 1993; Borel & Schlapfer, 1996); (c) vegetação (Peterson et al., 1988; Green, 1996; Sabol et al., 1996); (d) neve e gelo (Nolin & Dozier, 1993; Green & Dozier, 1996); (e) água (Hamilton et al., 1993; Kruse et al., 1997).

O primeiro sensor hiperespectral aerotransportado capaz de adquirir dados em bandas seqüencialmente dispostas ao longo do espectro solar refletido (de 0,4 a 2,5 μm) foi o sensor AVIRIS (*Airborne Visible/InfraRed Imaging Spectrometer*). Desenvolvido pela NASA (*National Aeronautics and Space Administration*) em 1983 (Vane et al., 1984), tornou-se operacional em 1987 (Green et al., 1998) após alguns ajustes e correções realizadas pelos pesquisadores do JPL (*Jet Propulsion Laboratory*), NASA. O desenvolvimento desse sistema teve como objetivo a obtenção de dados que pudessem ser utilizados nas diversas áreas das geociências (Carvalho Júnior et al., 2003).

Atualmente estão em operação e em planejamento algumas unidades de espectrômetros imageadores de uso científico e militar (Tabela 2.2), sendo a maior parte aerotransportada. O primeiro sensor hiperespectral a operar em órbita foi o sensor Hyperion, que será abordado no próximo item.

SENSOR	PLATAFORMA	ANO	ORIGEM	RESOLUÇÃO			INTERVALO ESPECTRAL
				ESPECTRAL	ESPACIAL	RADIOMÉTRICA	
AVIRIS	Aerotransportado	1987	NASA/JPL	224 bandas	20m/20Km 4m/4Km	12-bit	370-2500 nm
DAIS7915	Aerotransportado	1994	Ger. Corp.	79 bandas	1,5m/5Km 7m/25Km	15-bit	400-12500 nm
HYDICE	Aerotransportado	1995	EUA	210 bandas	1m/2Km 4m/8Km	12-bit	400-2500 nm
HyMAP	Aerotransportado	1996	Austrália	126 bandas	1,5m/1,5Km 13,5m/4,5Km	12 – 16 bit	450-2500 nm
AHI	Aerotransportado	-----	Hawai	256 bandas	variável	-----	700-11500 nm
CHRIS Proba	Orbital	2001	ESA	62 bandas	20 – 37 m	-----	400-1050 nm
HYPERION	Orbital	2000	NASA USGS	242 bandas	30 m	12-bit	400-2500 nm
HERO	Orbital	2010 (previsão)	Canadá	~250 bandas	30 m	12-bit	400-2500 nm
EnMAP	Orbital	2011 (previsão)	Alemanha	218 bandas	30 m	-----	420-2450 nm

TABELA 2.2 – Exemplos de sensores hiperespectrais orbitais e aerotransportados, operacionais e planejados para lançamento.

2.2.2 – Histórico satélite EO-1

O satélite EO-1 (*Earth Observing 1*) foi lançado em 21 de novembro de 2000, na Base da Força Aérea de Vandenberg – EUA, como parte do Programa do Novo Milênio (*New Millennium Program - NMP*) da NASA, tendo como principal objetivo avaliar novas tecnologias de sensores de alta performance e plataformas. O satélite EO-1 transporta três revolucionários instrumentos de imageamento do solo: o hiperespectral Hyperion, o multiespectral ALI (*Advanced Land Imager*) e o LAC (*LEISA Atmospheric Corrector*) que não se encontra mais em operação (Tabela 2.3).

Sua missão estava prevista para durar aproximadamente um ano. Contudo, devido ao grande interesse da comunidade científica, foi firmado um acordo entre a NASA e o USGS (*United States Geological Survey*) para a continuidade da missão.

Parâmetros	Multiespectral	Hiperespectral	
	ALI	HYPERION	LAC
Intervalo espectral	0,4 – 2,4 μm	0,4 – 2,5 μm	0,9 – 1,6 μm
Resolução espacial	30 m	30 m	250 m
Largura imagem	37 Km	7,5 Km	185 Km
Resolução espectral	Variável	10 nm	2-6 nm
Resolução banda Pancromática	10 m	ND	ND
Número de bandas	10	242	256

TABELA 2.3 - Característica dos sensores do EO-1.
 FONTE: Adaptada de Pearlman (2000).

2.2.3 – Órbita do satélite EO-1

O satélite EO-1 segue uma órbita circular Sol-síncrona a uma altura nominal de 705 Km do Equador, viajando no sentido norte-sul (descendente) com passagem equatorial média entre 10:00 e 10:15 da manhã. O EO-1 perfaz 14 órbitas por dia, com um ciclo de repetição de 16 dias.

O satélite EO-1 está próximo da órbita do Landsat 7, aproximadamente um minuto atrás (Figura 2.13). Isto permite ao EO-1 obter imagens das mesmas áreas, quase ao mesmo tempo, de modo que a comparação direta dos resultados possa ser obtida para o Landsat- ETM+ e os três instrumentos do E0-1. Depois do EO-1, quase na mesma órbita, está o SAC-C (satélite argentino) e o TERRA. Os quatro satélites constituem a “*morning constellation*”.




FIGURA 2.13 - Comparação da faixa de imageamento dos sensores ETM+, ALI, Hyperion e AC.

FONTE: Adaptada de Folkman (2000).

2.2.4 – Orientação dos sensores

A órbita do EO-1 segue o gride WRS-2 (*World Reference System-2*), com ciclo de repetição de 16 dias para imagens adquiridas no nadir. No entanto, os instrumentos a bordo do EO-1 são capazes de alterar seu apontamento, possibilitando a aquisição de imagens em órbita-ponto adjacentes à órbita corrente, tanto para leste quanto para oeste (Figura 2.14).

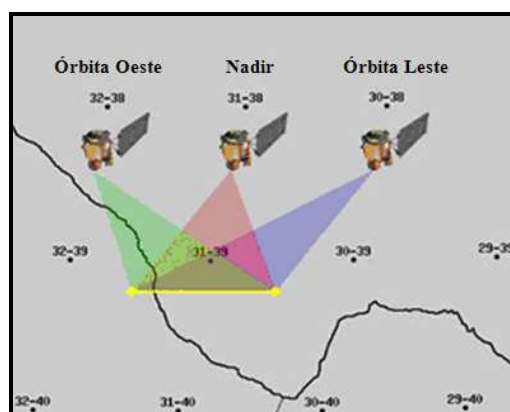


FIGURA 2.14 - Possibilidades de imageamento. Exemplo de possibilidade de programação para um alvo localizado na órbita 31 ponto 39.
FONTE: Disponível em <http://eo1.usgs.gov/userGuide/index.php?page=orbit_data>.

Desta forma, há três possibilidades de aquisição para um determinado alvo, dentro do ciclo de 16 dias:

1. Nadir (uma vez a cada 16 dias)
2. Órbita oeste apontando para leste (7 dias após a passagem nadir)
3. Órbita leste apontando para oeste (9 dias após a passagem nadir)

2.2.5 – Ângulo de visada EO-1

A maioria das imagens adquiridas pelo EO-1 é obtida com pequenos ângulos de apontamento ou visada, que configuram uma aquisição ao nadir. Para diminuir o tempo de revisita de cena, outras imagens são obtidas com ângulos de apontamento maiores, algumas vezes superiores a 25 graus do nadir.

O ângulo de visada dependerá da localização do alvo dentro do WRS-2, assim como de sua latitude (Tabela 2.4). Em geral, a variação do ângulo de visada será menor quanto maior a latitude (regiões polares).

Latitude	Órbita oeste Sensor apontando para leste (graus)	Nadir (graus)	Órbita leste Sensor apontando para oeste (graus)
80 N	0,716 a 2,145	+ - 0,716	- 0,716 a - 2,145
60 N	3,369 a 10,015	+ - 3,369	- 3,369 a - 10,015
45 N	4,856 a 14,297	+ - 4,856	- 4,856 a - 14,297
30 N	5,975 a 17,433	+ - 5,975	- 5,975 a - 17,433
15 N	6,672 a 19,338	+ - 6,672	- 6,672 a - 19,338
0	6,909 a 19,976	+ - 6,909	- 6,909 a - 19,97
15 S	6,672 a 19,338	+ - 6,672	- 6,672 a - 19,338
30 S	5,975 a 17,433	+ - 5,975	- 5,975 a - 17,433
45 S	4,856 a 14,297	+ - 4,856	- 4,856 a - 14,297
60 S	3,369 a 10,015	+ - 3,369	- 3,369 a - 10,015
80 S	0,716 a 2,145	+ - 0,716	- 0,716 a - 2,145

TABELA 2.4 - Variação do ângulo de visada para latitudes específicas.
 FONTE: Disponível em <http://eo1.usgs.gov/userGuide/index.php?page=orbit_data>.

2.2.6 – Sensor Hiperespectral Hyperion – EO-1

O espectrômetro imageador Hyperion herdou algumas características do Instrumento de Imageamento Hiperespectral LEWIS (HSI), que falhou em órbita. O Hyperion é o primeiro imageador hiperespectral da NASA a estar operando em órbita terrestre. Sua missão é avaliar as potencialidades dos espectrômetros imageadores baseados no espaço para observação da Terra.

Concebido originalmente como parte do instrumento ALI, o Hyperion é um instrumento completo e independente do EO-1. Os principais componentes deste instrumento possuem:

- Sistema com desenho baseado na missão KOMPSAT EOC.

- Um arranjo de planos focais que fornecem detectores de ondas curtas separadas (*Short Wave Infrared* - SWIR) e espectro visível e infravermelho próximo (*Visible and Near infrared* - VNIR) baseados em hardware sobressalente do programa LEWIS HSI.
- Um *cryocooler* idêntico ao fabricado para a missão LEWIS HSI para refrigeração do plano focal SWIR.

O Hyperion (Figura 2.13) fornece imagens hiperespectrais em 242 bandas espectrais (356 a 2577 nm), em intervalos médios de 10 nm, e com resolução espacial de 30 metros (Tabela 2.5). Os dados são adquiridos por dois espectrômetros imageadores (*pushbroom*): um no visível e infravermelho próximo (VNIR) cobrindo o intervalo do espectro eletromagnético de 0.4 – 1.0 μm , e outro no infravermelho de ondas curtas (SWIR), cobrindo o intervalo 0.9 – 2.5 μm (Kruse, 2002).

Parâmetros	Sensor Hyperion
GSD a 705 Km de altitude	30 m
Intervalo espectral	0,4 – 2,5 μm
Vida útil	1 ano (objetivo 2 anos)
IFOV	42,5 μrad
Número de bandas espectrais	242
Largura da banda	10 nm
Peso do instrumento	49 Kg
Consumo de energia	78 Watts em órbita

TABELA 2.5 - Principais características do sensor Hyperion.
 FONTE: Adaptada de Folkman (2000).

Nem todas as bandas do sensor Hyperion são calibradas (para o produto nível 1R do USGS) (Tabela 2.6). Isto se deve principalmente à diminuição da resposta do detector nos menores comprimentos de onda. Assim, o produto final dos dados fornece um total de 198 bandas, que representam o espectro contínuo de 427 a 2395 nm.

As bandas adquiridas e calibradas incluem também uma pequena área de sobreposição entre os espectrômetros VNIR e SWIR (bandas 56-57 e 77-78; de ~912

a ~923 nm). Conseqüentemente, excluindo duas dessas bandas, tem-se ao final 196 bandas espectrais.

	Banda #	Comprimento de onda (nm)	Status
VNIR	1 - 7	356 - 417nm	Não calibrada
	8 - 55	426 - 895 nm	Calibrada
	56 - 57	913 - 926 nm	Calibrada (sobreposição com SWIR 77-78)
	58 - 70	936 - 1058 nm	Não calibrada
SWIR	71 - 76	852 - 902 nm	Não calibrada
	77 - 78	912 - 923 nm	Calibrada (sobreposição com VNIR 56-57)
	79 - 224	933 - 2396 nm	Calibrada
	225 - 242	2406 - 2578 nm	Não calibrada

TABELA 2.6 - Bandas calibradas vs. não calibradas.

FONTE: Disponível em <http://eo1.usgs.gov/userGuide/index.php?page=hyp_prod>.

A imagem obtida pelo sensor Hyperion (Figura 2.15) cobre aproximadamente 7,7 Km da superfície terrestre no sentido perpendicular à direção de vôo, podendo variar em sua extensão de 42 Km a 185 Km, dependendo da programação. O produto final Nível 1R possui 256 colunas e aproximadamente 1400 linhas para cada banda de uma imagem padrão (42 Km) e aproximadamente 6170 linhas para uma imagem estendida (185 Km).




FIGURA 2.15 - Sensor Hyperion.
FONTE: Adaptada de Folkman (2000)

2.2.7 – Correção Nível 1R (USGS)

Os dados Hyperion são comercializados pelo USGS em dois níveis de correção. O Nível 1R, que será descrito a seguir e o Nível 1Gst, que além das correções aplicadas no Nível 1R recebe a correção geométrica. Ambos os níveis são

fornecidos em valores de radiância de 16 bits e no formato HDF (*Hierarchical Data Format*) ou GeoTIFF (*Geographic Tagged Image-File Format*) (somente para o Nível 1Gst).

Os algoritmos aplicados no Nível 1R envolvem:

1) Correção de dois tipos de artefatos que afetam o SWIR: (1) *smear*, que é o escoamento do sinal de um pixel para outro, e (2) *eco*, o qual ocorre quando o sinal de uma imagem “eco” para o próximo pixel;

2) Remoção de fundo “*bias*”;

3) Calibração radiométrica, obtida pela multiplicação da imagem resultante do processo *dark subtraction*, pelos valores de ganho;

4) Reescalonamento dos valores ND (Número Digital), onde são aplicados dois diferentes fatores na imagem em radiância. Para as bandas calibradas no VNIR (8-57), a imagem é multiplicada por 40 e, para as bandas calibradas no SWIR (77-224), a imagem é multiplicada por 80;

5) Geração da máscara de pixels anômalos (*bad pixel mask*). Esta máscara é baseada na lista de pixels anômalos que foram definidos no teste de pré-lançamento, com uma atualização de 2001. A máscara de pixels anômalos utiliza os seguintes valores para os detectores defeituosos:

0 = Dado normal;

1 = Pixel saturado;

2 = Detector sem resposta a luz (valor 0);

3 = Detector sem resposta, mas com um valor constante;

4 = *Overflow* (valores excederam o intervalo de calibração).

6) Alinhamento VNIR/SWIR, que implica no deslocamento das bandas do SWIR para o valor nominal das bandas do VNIR;

7) O passo final no Nível 1R envolve a preparação dos dados para o formato HDF (*Hierarchical Data Format*), adicionando o centro do comprimento de onda de cada banda (*spectral center wavelengths* - CWL) e a largura espectral de cada banda (*full-width-half-max* - FWHM). Um arquivo *header* é gerado no formato ENVI (*ENvironment for Visualizing Images*) e, por fim, todos os arquivos são comprimidos, podendo ser entregues via FTP (*File Transfer Protocol*).

Os valores de radiância são expressos em $W / (m^2 * sr * \mu m)$.

O produto final L1R é constituído por cinco arquivos, contendo a imagem radiometricamente corrigida, o valor do centro de comprimento de onda de cada banda – CWL, a largura nominal de cada banda - FWHM, os coeficientes de ganho e a máscara (*flag mask*), além do arquivo *header* no formato ENVI.

2.2.8 – Relação Sinal-Ruído (SNR)

A qualidade dos dados de sensoriamento remoto está diretamente relacionada com o nível de ruído do sensor em relação ao sinal recebido. Isto é geralmente expresso como Relação Sinal-Ruído (*Signal to Noise Ratio* - SNR), que descreve o desempenho do sistema radiométrico. O ruído está vinculado ao desenho do sensor e leva em consideração fatores como o desempenho do detector/sensibilidade, resolução espacial/espectral, o ruído e as características do sistema eletrônico. Embora os níveis de ruído para um dado sensor sejam geralmente fixos para aquisição de dados de sensoriamento remoto, o SNR é afetado por outros fatores externos, como o ângulo solar zenital, atenuação atmosférica e espalhamento, que modifica o sinal captado pelo sensor em diferentes comprimentos de onda (Kruse, 2003).

A relação sinal-ruído do Hyperion foi determinada através da combinação da medida função-resposta com um modelo de referência. As condições que serviram de referência assumiram um ângulo solar zenital de 60° e albedo uniforme de 30%. O desempenho da relação sinal-ruído é mostrado na Figura 2.16. Os valores representados por quadrados são os valores medidos durante a caracterização do

Hyperion. A curva contínua é o ajuste do modelo utilizando as condições de referência (Pearlman et al., 2000).

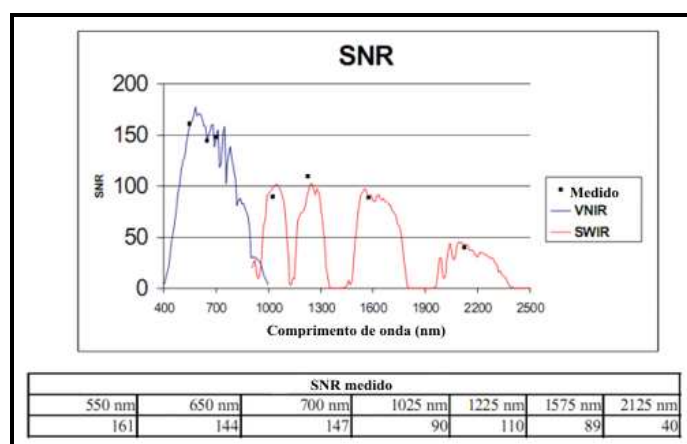


FIGURA 2.16 - Relação sinal-ruído do sensor Hyperion.
 FONTE: Adaptada de Pearlman (2000).

2.2.9 – Aplicações

Inúmeros trabalhos, nas mais variadas áreas, têm utilizando o sensor hiperespectral Hyperion como fonte de dados. Alguns exemplos, dentro uma ampla gama de aplicações, incluem: (a) Numata et al. (2008), que testaram o potencial dos sensores Hyperion e ETM+ para estimar as propriedades biofísicas de pastagem no Estado de Rondônia; (b) Walsh et al. (2008), que utilizaram dados QuickBird e Hyperion para avaliar a distribuição espacial da espécie invasiva *Psidium guajava* nas Ilhas Galápagos, Equador; (c) Giardino et al. (2007), que avaliaram a qualidade da água no Lago Garda – Itália, através de um modelo bio-óptico aplicado sobre dados Hyperion; (d) Reinart & Kutser (2006), que utilizaram um modelo bio-óptico em uma imagem do sensor hiperespectral Hyperion, obtida na parte ocidental do Golfo da Finlândia – Mar Báltico, para demonstrar que a concentração de clorofila pode variar de um a centenas de mg/m³ durante a floração de cianobactérias tóxicas; e (e) Galvão et al. (2005), que avaliaram o potencial dos dados hiperespectrais coletados pelo sensor Hyperion em uma área de estudo localizada no Estado de São Paulo para a discriminação de cinco variedades de cana-de-açúcar.

2.3 – Pré-Processamento de imagens Hyperion

2.3.1 – *Destriping*

As imagens obtidas pelo sensor Hyperion apresentam ruídos (pixels anômalos) que estão relacionados ao tipo de tecnologia de varredura (*pushbroom*) utilizada. Estes sensores de varredura geram imagens onde cada coluna em uma única banda, corresponde a um único detector em um dos arranjos. Como estes detectores não estão bem calibrados, tanto no espectrômetro do VNIR como do SWIR, aparecem faixas verticais ou “*stripes*” na banda da imagem resultante (Figura 2.17), especialmente nas doze primeiras bandas do VNIR e outras tantas no SWIR (Datt et al., 2003; Goodenough et al., 2002) (Tabela 2.7). Este *striping* não significa que os pixels apresentam valores defeituosos, mas sim que possuem valores de ganho (*gain*) e de compensações (*offset*) diferentes (Ducart et al., 2007). Somente nos casos mais extremos estes pixels contêm pouca ou nenhuma informação (Datt et al., 2003; Goodenough et al., 2002).

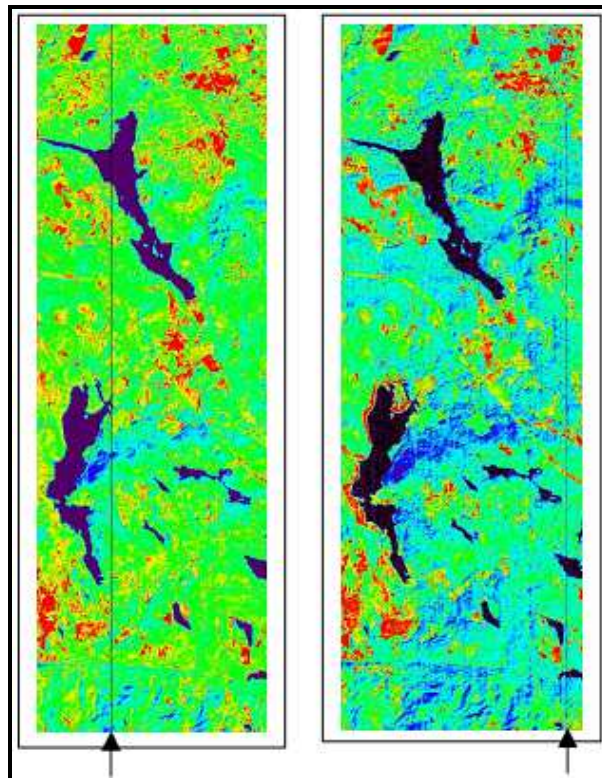


FIGURA 2.17 – Pixels anômalos nas bandas 94 e 119.
FONTE: Adaptada de Han et al. (2002)

Goodenough et al. (2002) classificaram os *stripes* em quatro categorias:

- 1) Contínuos com valores de ND atípicos - geralmente se manifestam com ND extremamente baixo (-32768, p. ex.);
- 2) Contínuos com valores de ND contínuos – apresentam ND constante em uma coluna inteira;
- 3) Intermitentes com valores de ND atípicos – aparecem como pequenos pontos escuros, com valores de ND extremamente baixos;
- 4) Intermitentes com baixos valores de ND – sendo o caso mais comum. Possuem baixo ND se comparados com os pixels vizinhos.

Banda	Coluna	Banda	Coluna
5	114; 141	57	13
6	6; 68; 172	75	2
7	7; 68; 179; 185	94	82
8	7; 12; 68; 114;121	99	81
9	6; 68; 114	116	127
10	6; 114; 131; 199	119-1120	240
11	6; 114; 199	121	196
12	6; 114	125	54; 115; 160; 164
13	114	127	40; 66; 213
14	114; 247	128	30; 96; 126
15-26	114	165	148
27-28	47-114	168	245
29-34	114	169	12; 23
39	177	190	113
40	13	200-201	8
48-51	20	203	104-115
52	13; 33	222	98
53	33	225	186

TABELA 2.7 – Localização dos *stripes* nos dados Hyperion.
 FONTE: Adaptada de Goodenough (2002).

Segundo Ducart et al. (2007), o *striping* representa um obstáculo para as etapas posteriores do processamento dos dados, produzindo um tipo de ruído que se

torna evidente quando são aplicadas técnicas tais como razão de bandas, análise por principais componentes ou também MNF (*Minimum Noise Fraction*). A correção deste problema, também chamada *destriping*, deve ser aplicada anteriormente à correção atmosférica. Existem alguns métodos descritos na bibliografia que, aparentemente, corrigiriam este problema, mas sua aplicação não é trivial (Jupp & Bisun, 2001; Datt et al., 2003; Goodenough et al., 2003; Kruse et al., 2003). Kruse et al. (2003) utilizaram um software customizado para o *destriping*, seguindo o modelo de software escrito para o espectrômetro imageador *pushbroom* (AIS).

Na prática, um algoritmo é utilizado para localizar as colunas e pixels defeituosos e substituir seus valores espectrais pelos valores médios das colunas vizinhas.

2.3.2 – Correção efeito *Smile*

O efeito *smile* ocorre devido ao deslocamento do centro de comprimento de onda nominal (Figura 2.18) da banda na trajetória perpendicular do satélite. Segundo Goodenough et al. (2003), este efeito ocorre em todos os dados Hyperion.

De acordo com Barry (2001), os deslocamentos dependem diretamente da posição do pixel na direção perpendicular à trajetória. Para as bandas situadas no VNIR, os deslocamentos variam de 2,6 a 3,5 nm, sendo que, o deslocamento máximo ocorre no pixel 256 da banda 10. Para as bandas do SWIR, os deslocamentos são menores que 1 nm.

A presença do efeito *smile* somente é percebida no espaço MNF (*Minimum Noise Fraction*). Imagens com significativo efeito *smile* aparecem com um gradiente na primeira componente MNF (Figura 2.19).

Segundo Goodenough et al. (2003), o efeito *smile* em dados Hyperion não pode ser corrigido, mas sim minimizado por interpolação. A impossibilidade de se eliminar esta anomalia deve-se ao fato de que os dados utilizados para corrigi-la são provenientes da calibração de campo, antes do lançamento da plataforma EO-1, e provavelmente os dados de calibração foram alterados após o lançamento em órbita.

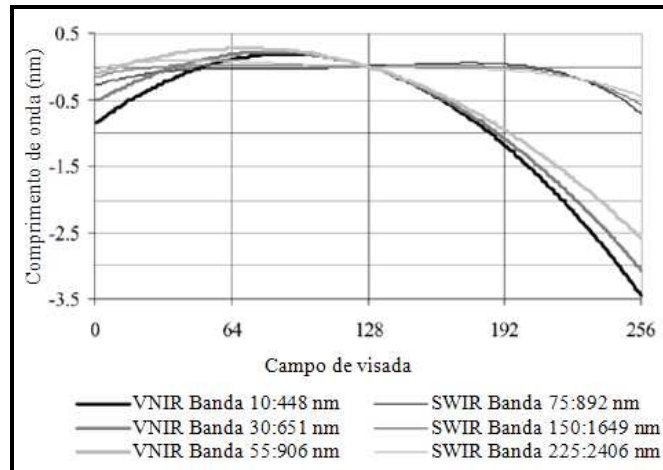


FIGURA 2.18 - Variação do centro do comprimento de onda (efeito *smile*) na região do VNIR e SWIR em dados Hyperion.
 FONTE: Goodenough (2003).




FIGURA 2.19 - Exemplo do efeito *Smile* em dados Hyperion. Da esquerda para direita: 1ª componente MNF do VNIR e 1ª componente MNF do SWIR.
 FONTE: Goodenough (2003).

2.3.3 – Correção Atmosférica

A utilização de imagens de sensores de alta resolução espectral, adquiridas de plataformas orbitais ou aerotransportadas, requer a correção dos efeitos de absorção e

espalhamento causados pela presença de gases e aerossóis, que afetam o sinal recebido pelo sensor (Tanré et al., 1990). As principais evidências desses efeitos sobre a imagem são a diminuição do brilho da superfície em regiões espectrais específicas e a presença de névoa, com perda de nitidez, nas regiões dos menores comprimentos de onda (Latorre et al., 2002). Desta forma, a correção atmosférica é fundamental para a classificação espectral dos alvos, pois possibilita a análise comparativa dos valores de reflectância obtidos pelo sensor orbital com diversas fontes (ex. bibliotecas espectrais) de espectros de materiais conhecidos, presentes na superfície terrestre (Ducart, 2004; Kim et al., 2007).

Enquanto o espalhamento molecular e por aerossóis é marcante na região do visível, a absorção pelos gases atmosféricos ocorre principalmente na região de 1,0 a 2,5 μm (Figura 2.20). Praticamente metade do espectro entre 0,4 μm – 2,5 μm é afetada pela absorção atmosférica (Gao et al., 1993).

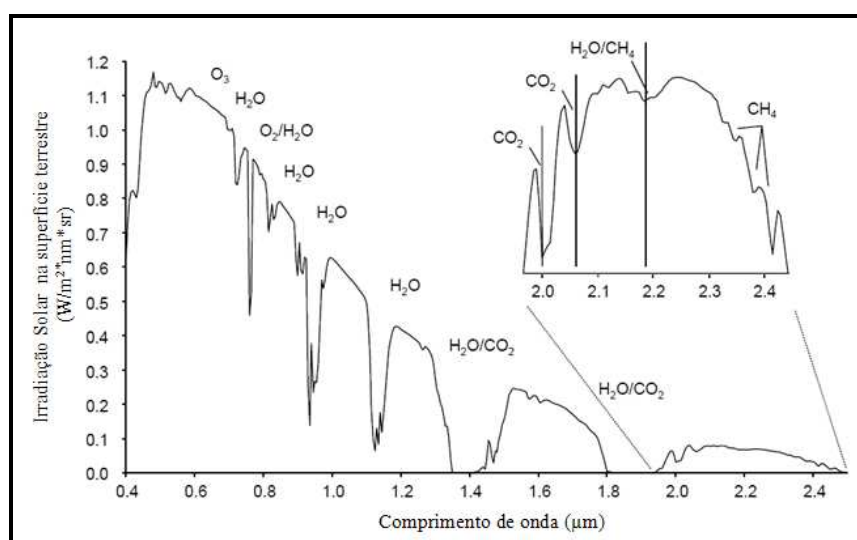


FIGURA 2.20 - Irradiação solar e absorção atmosférica causada por O_3 , H_2O , O_2 , CO_2 e CH_4 .

FONTE: Adaptada de Chabrillat (2007).

Com o advento da espectroscopia de imageamento, verifica-se uma tendência para modelos de correção atmosférica do tipo distribuído, que realizam um tratamento específico pixel a pixel. Esse avanço foi possível devido à capacidade de detecção das feições de absorção dos elementos atmosféricos pelos sensores hiperespectrais, que fornecem uma estimativa da quantidade de gases e aerossóis presentes (Green, 1990;

Gao et al., 1993), podendo-se utilizar dados da própria imagem para estimar a presença de constituintes importantes da atmosfera, como o vapor d'água, e para aperfeiçoar a modelagem de outros constituintes.

Programas como o ATREM (*ATmosphere REMoval program*) (Gao & Goetz, 1990; Gao et al., 1993), HATCH (*High Accuracy Atmospheric Correction for Hyperspectral data*) (Qu et al., 2000; Kindel et al., 2000), ACORN (*Atmospheric CORrection Now*) e FLAASH (*Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes*) oferecem opções variadas de entradas de dados provenientes da caracterização da atmosfera, principalmente em relação às concentrações de vapor d'água, O₃, profundidade óptica e tipo de concentração de aerossóis. Há a possibilidade ainda de informar parâmetros referentes às propriedades espectrais de objetos vizinhos àquele que se pretende corrigir o efeito da atmosfera sobre seus valores de Fator de Reflectância Bidirecional (FRB)³ aparente apresentados em imagens orbitais (Ponzoni & Shimabukuro, 2007).

Embora cada programa utilize uma versão ligeiramente diferente e o algoritmo FLAASH acrescente um termo para efeitos de adjacência (Adler-Golden et al., 1999), todos se baseiam no modelo de transferência radiativa mostrado abaixo (Gao & Goetz, 1990).

$$L_0(\lambda) = L_{solar}(\lambda) * T(\lambda) * R(\lambda) * \cos(\theta) + L_{atmosfera}(\lambda) \quad (2.1)$$

Onde:

(λ) = comprimento de onda;

L_0 = radiância captada pelo sensor;

$L_{solar}(\lambda)$ = radiância solar acima da atmosfera;

$T(\lambda)$ = transmitância total da atmosfera;

$R(\lambda)$ = reflectância de superfície;

θ = ângulo de incidência;

$L_{atmosfera}(\lambda)$ = radiância espalhada pela coluna atmosférica.

³ O FRB representa a quantidade relativa de radiação eletromagnética que é refletida por uma dada superfície ou objeto, para uma dada condição geométrica de iluminação e visada.

A principal vantagem da aplicação desses modelos de transferência radiativa, segundo Ponzoni & Shimabukuro (2007), é que estes modelos consideram também o fenômeno de absorção da radiação eletromagnética, o que implica em resultados frequentemente mais confiáveis quando o interesse é correlacionar os valores de FRB presentes nas imagens com parâmetros geofísicos ou biofísicos de objetos existentes na superfície terrestre.

Kruse (2004) realizou um estudo comparativo dos resultados obtidos com os programas ATREM, ACORN e FLAASH para correção atmosférica dos dados adquiridos pelo sensor hiperespectral AVIRIS sobre a Cidade de Boulder, Colorado. Os dados foram corrigidos utilizando parâmetros similares para cada programa e os resultados foram comparados com espectros coletados em campo. Em resumo, os três modelos produziram espectros de reflectância bastante similares com os espectros medidos em campo, porém o FLAASH mostrou-se mais flexível para correção de dados hiperespectrais, considerando as opções disponíveis no MODTRAN (*MODerate resolution atmospheric radiance and TRANsmittance Model*), além de corrigir os efeitos de adjacência. O espaço em disco requerido pelo FLAASH para as etapas de processamento, no entanto, foi consideravelmente maior, ficando na ordem de 5 vezes o tamanho do arquivo a ser corrigido.

2.3.4– Correção Geométrica

A correção geométrica de imagens obtidas por sensores orbitais é essencial quando se deseja relacionar os dados de campo com os dados medidos pelo sensor (Goodenough et al., 2002). Sua função é reorganizar os “pixels” da imagem em relação a um determinado sistema de projeção cartográfica, objetivando minimizar as distorções geométricas, provenientes das características do sensor utilizado e das variações decorrentes do movimento do mesmo durante a passagem sobre o alvo.

Richards & Jia (2006) discutiram duas técnicas de correção geométrica que podem ser utilizadas para corrigir os variados tipos de distorção geométrica presentes nos dados de imagens orbitais. A primeira técnica modela a natureza e a magnitude das fontes de distorção e utiliza estes modelos para estabelecer uma fórmula de

correção. Entretanto, esta técnica só é eficaz quando os tipos de distorção são bem caracterizados, como aqueles causados pela rotação da Terra.

A segunda abordagem estabelece uma transformação polinomial do sistema de referência da imagem. Os parâmetros do polinômio são definidos por um ajuste por mínimos quadrados entre a posição dos pixels da imagem e as coordenadas geográficas correspondentes no campo, utilizando informações de cartas, pontos coletados “*in situ*” ou outra imagem georreferenciada. Esta transformação pode ser utilizada para corrigir a geometria da imagem, independente do conhecimento das fontes de distorções, tipos de distorções e da plataforma usada para aquisição de dados.

Segundo Dyk et al. (2002), dados Hyperion podem ser geocorrigidos com surpreendente precisão. Em seus estudos, foram obtidos 13 m de erro RMS utilizando polinômio de segunda ordem, sem correção de terreno. Aplicando correção de terreno, houve significativa melhora na precisão da correção geométrica em áreas com alto relevo.

2.4 - Modelo Linear de Mistura Espectral

2.4.1 - Mistura Espectral

A resposta espectral de um pixel é o resultado da mistura da resposta espectral dos materiais que formam este pixel (Figura 2.21), a não ser que dentro dele esteja presente exclusivamente um único material. Essa mistura espectral ocorre em todas as escalas, desde a escala microscópica de grãos minerais, onde a mistura é tipicamente não-linear, até a escala macroscópica (quilômetros), como classes de cobertura de solo (Dennison & Roberts, 2003; Ponzoni & Shimabukuro, 2007).

A mistura não-linear ocorre devido ao espalhamento múltiplo, em que um mesmo fóton interage com mais de um alvo, podendo-se tornar expressiva em superfícies com cobertura vegetal (copas de árvores) e solos (Huete, 1986; Roberts et al., 1993; Borel & Gerstl, 1994; Ray & Murray, 1996).

Segundo Ponzoni & Shimabukuro (2007), pode-se dizer que o valor associado a cada pixel de uma imagem representa a radiância média dos materiais presentes na superfície em uma determinada banda espectral, somada a interferência da atmosfera. A radiância registrada pelo sensor depende das características do sensor (p.ex. resolução espacial), das propriedades físico-químicas dos materiais presentes no pixel e da interferência atmosférica.

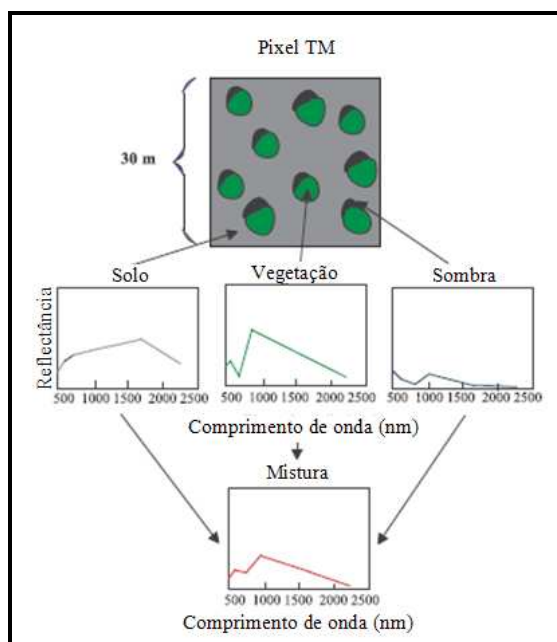


FIGURA 2.21 - Mistura espectral causada pela variedade de materiais no pixel.
 FONTE: Adaptada de Chabrillat (2007).

De certa forma, essa mistura espectral é indesejada, pois mascara a resposta característica de cada alvo, dificultando assim a aplicação das técnicas de classificação digital de imagens orbitais que se fundamentam exclusivamente no domínio espectral (radiométrico), pois estas consideram que um dado pixel contém uma medida de radiância de um único objeto.

2.4.2 – Algoritmo do modelo de Análise de Mistura Espectral (SMA)

A análise de mistura espectral teve início na década de 70, no tratamento de imagens multiespectrais (Horwitz et al., 1971, 1975; Richardson et al., 1975; Adams & Adams, 1984; Huete, 1986; Huete et al., 1986), obtendo grande propagação em estudos astronômicos com propósito de definir a composição superficial de astros

(Singer & McCord, 1979; Adams & Smith, 1986; Mustard & Head, 1996, Smith et al., 1985). Com o advento do sensor *Airborne Imaging Spectrometer* (AIS), Smith & Adams (1985) transferiram e aprimoraram a metodologia para imagens hiperespectrais onde foram realizados inúmeros trabalhos (Mustard, 1993; Ustin et al., 1992; Roberts et al., 1993 entre outros). Inúmeros desses estudos buscam a determinação da proporção (fração) de cobertura no pixel, assumindo que a resposta espectral é uma combinação linear da resposta dos constituintes “puros” em cada banda utilizada (Richards & Jia, 2006).

Segundo Shimabukuro & Smith (1991), a relação linear é usada para representar a mistura espectral de alvos contidos no pixel. Seguindo esta abordagem, a resposta de cada pixel, em qualquer comprimento de onda pode ser considerada como uma combinação linear das respostas de cada componente (p.ex. água, solo, vegetação, sombra), que será assumida na mistura. Desta forma, cada pixel da imagem, que assume qualquer valor dentro da escala de cinza, contém informações sobre a proporção e a resposta espectral de cada componente dentro do pixel.

A Análise de Mistura Espectral (*Spectral Mixture Analysis* - SMA), proposta por Smith et al. (1985), é um modelo linear baseado na mistura espectral de dois ou mais componentes ou Membros de Referência (MRs - *endmembers*) (Adams et al., 1993), que permite representar a variabilidade na composição e iluminação de uma imagem. Os pixels da imagem (espectros medidos dentro do campo de visada instantâneo – IFOV) são modelados como a mistura linear de MRs, onde, um MR de sombra é utilizado para representar a variação de iluminação, e um ou mais MRs (não-sombra) para representar os diferentes materiais da imagem.

Na SMA, a reflectância do pixel (ρ'_λ) é determinada pela soma das reflectâncias de cada material contido no pixel, multiplicado pela fração de cobertura:

$$\rho'_\lambda = \sum_{i=1}^N f_i * \rho_{i\lambda} + \epsilon_\lambda \quad (2.2)$$

onde $\rho_{i\lambda}$ é a reflectância do MR i para uma banda específica (λ), f_i é a fração do MR, N é o número de MRs e ε_λ é o erro residual. Como a soma das proporções, para qualquer resolução, deve ser igual a um, as frações modeladas dos MRs são restringidas por:

$$\sum_{i=1}^N f_i = 1, \text{ onde } 0 \leq f_i \leq 1 \quad (2.3)$$

O ajuste do modelo é avaliado pelo seu erro residual (ε_λ) ou Raiz do Erro Médio Quadrático (*Root Mean Square Error* - RMSE).

$$RMSE = \sqrt{\frac{\sum_{\lambda=1}^M (\varepsilon_\lambda)^2}{M}} \quad (2.4)$$

Onde M é o número de bandas. SMA tipicamente assume somente interações entre fótons e superfícies, produzindo uma mistura linear das frações de superfície e seus valores de reflectância.

A partir da aplicação do algoritmo de mistura são geradas tantas imagens quantos forem as componentes puras identificadas pelo modelo. No caso específico do modelo desenvolvido por Shimabukuro & Smith (1991), são consideradas componentes puras de um pixel de imagem TM - Landsat a vegetação, a sombra e o solo, sendo possível, portanto, decompor cada pixel de uma imagem nas proporções de sombra, vegetação e solo que o compõe. Essas imagens são conhecidas por imagens-fração ou proporção, em número variável de acordo com o número de elementos selecionados como constituintes da mistura espectral (MRs) (Vasconcelos & Novo, 2004).

2.4.3 – Modelo de Análise de Mistura Espectral com Múltiplos Membros de Referência (MESMA)

Embora a SMA seja uma poderosa abordagem, ela falha em não considerar a variabilidade espectral de um mesmo material, visto que o modelo utiliza somente um

MR por material. Além disso, os MRs utilizados no modelo são os mesmos para todos os pixels da imagem, independente se os materiais representados por eles estão presentes ou não no pixel, produzindo consideráveis frações de erro (Roberts et al., 1997).

Para corrigir essa fonte de erro foi proposto um novo método que estabelece para cada pixel o melhor modelo de mistura a partir do menor valor do erro médio quadrático (Smith et al., 1992; Sabol et al., 1992b; Roberts et al., 1992). A evolução dessa proposta deu origem ao modelo MESMA (*Multiple Endmember Spectral Mixture Analysis*) (Roberts et al., 1998a), que permite que o número e tipo de MR variem pixel-a-pixel.

O MESMA calcula a fração dos MRs, a raiz do erro médio quadrático e o seu respectivo resíduo. Assim, os pesos dos coeficientes do modelo de mistura são determinados como uma combinação linear dos seus MRs, de tal forma que se obtenha o menor erro médio quadrático, quando comparado com a curva espectral do pixel, utilizando combinações de dois, três ou quatro MRs em cada pixel. Utilizando esta abordagem, os erros de fração são minimizados através da seleção do modelo de melhor ajuste para cada pixel. O peso dos coeficientes varia de 1 até 0 e o ajuste é restrito para um limite de erro médio quadrático aceitável. Como passo final, o modelo para cada pixel com menor RMSE é identificado (Okin et al., 1998).

O MESMA tem sido aplicado no mapeamento de áreas com cobertura de neve (Painter et al., 1998; 2003), no mapeamento de espécies vegetais em região de chaparral (Roberts et al., 1998; Dennison & Roberts, 2003a/2003b; Roberts et al., 2003), no mapeamento de solos em terras áridas (Okin et al., 2001), na caracterização da temperatura do fogo (Dennison et al., 2006), no sensoriamento remoto de áreas urbanas (Rashed et al., 2003; Powell et al., 2007) e até mesmo em várias aplicações planetárias (Li & Mustard, 2003; Johnson et al., 2006).

2.4.4 - Seleção de Pixels Candidatos a Membros de Referência

Segundo Tompkins et al. (1997), a seleção de MRs é essencial para o bom desempenho de modelos de mistura, pois estes representarão toda a informação

espectral contida na cena. O conjunto ideal de MRs deve apresentar espectros que, quando combinados linearmente, sejam capazes de reproduzir qualquer espectro da cena sob análise. Os MRs podem ser selecionados de pixels “puros” da própria imagem (membros derivados), medidos em campo ou laboratório, ou então criados como MRs “virtuais” (Gillespie et al., 1990; Adams et al., 1993; Tompkins et al., 1997). Rashed et al. (2003) recomendam obter os componentes da própria imagem, pois, dessa forma, há compatibilidade com a resolução espacial da imagem, tornando mais fácil associá-los às feições na cena. Típicos MRs usados na SMA incluem solo, vegetação verde (*Green Vegetation* - GV), vegetação não-fotossinteticamente ativa (*Nonphotosynthetic Vegetation* - NPV) e sombra.

Uma série de abordagens tem sido desenvolvida para a identificação de MRs, incluindo: Índice de Pureza do Pixel (*Pixel Purity Index* – PPI) (Boardman et al., 1995), seleção manual (Bateson & Curtiss, 1996; Rosso et al., 2005), *Endmember Bundles* (Bateson et al., 2000), *Constrained Reference Endmember Selection* (CRES: Roberts et al., 1993; 1998a), *Count-based Endmember Selection* (CoB: Roberts et al., 2003), *Endmember Average RMSE* (EAR: Dennison & Roberts, 2003a) e *Minimum Average Spectral Angle* (MASA: Dennison et al., 2004). As técnicas CoB, EAR, MASA e CRES para identificação de MRs estão implementadas no módulo VIPER (*Visualization and Image Processing for Environmental Research*) Tools (Roberts et al., 2007) Tools e serão posteriormente abordadas.

Dennison & Roberts (2003a) extraíram manualmente MRs a partir de 57 polígonos (40 x 40 m) de referência digitalizados sobre uma imagem AVIRIS, mapeados através de levantamento de campo e ortofotos. Para satisfazer o critério de seleção dos espectros, os polígonos deveriam possuir 75 - 100 % de dominância de uma única classe, e os pixels, inteiramente inseridos no polígono.

A metodologia utilizada por Boardman & Kruse (1994), para a detecção dos MRs derivados, apresenta três etapas: (a) redução da dimensão espectral (*Minimum Noise Fraction* - MNF), (b) redução da dimensão espacial (*Purity Pixel Index* - PPI), e (c) identificação manual (utilizando um visualizador n-dimensional). Segundo Carvalho et al. (2001), essa metodologia visa eliminar os fatores redundantes, tanto espaciais como espectrais, que nada alteram o conjunto de soluções viáveis para os

MRs, sendo amplamente utilizada em trabalhos com imagens hiperespectrais (Richardson et al., 1994; Richardson, 1996; Kruse, 1996; Kruse, 1999).

Rosso et al. (2005) avaliaram o desempenho dos modelos de mistura SMA e MESMA utilizando MRs selecionados a partir da metodologia proposta por Boardman & Kruse (1994) e os extraídos manualmente da própria imagem de áreas onde as espécies de interesse pareciam homogêneas em fotografias aéreas de alta resolução com suporte de mapas de vegetação. As duas listas de candidatos a MRs, manual e semi-automática, foram mantidas em separado para análise. O SMA foi aplicado a diferentes combinações de MRs de cada lista e posteriormente os resultados obtidos sobre 100 polígonos (20 x 20 m) de referência foram comparados. Os resultados obtidos demonstraram que os modelos “manual” apresentaram maior correlação do que os modelos semi-automáticos (MNF, PPI e *n*-D visualizador) (Figura 2.22). No entanto, os modelos com melhor Coeficiente de Correlação Intraclasse (*Intraclass Correlation Coefficient* – ICC) foram obtidos utilizando a abordagem de Boardman & Kruse (1994) (ICC = 0,56).

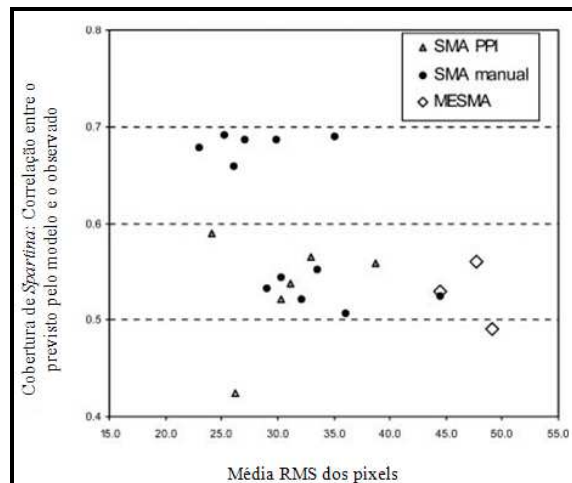


FIGURA 2.22 - Desempenho dos modelos de mistura SMA utilizando MRs selecionados pelo processo semi-automático e manual. O modelo MESMA foi aplicado somente com MRs obtidos pelo processo manual. As relações entre as frações de *Spartina* medidas e estimadas com os valores de erro médio quadrático (RMSE) são mostradas.

FONTE: Rosso et al. (2005).

2.4.4.1 – Transformação MNF (*Minimum Noise Fraction*)

Os dados hiperespectrais constituem, sem dúvida, uma grande fonte de informação. No entanto, há três fatores que devem ser considerados: (a) o alto grau de correlação entre as bandas, devido ao elevado número de bandas estreitas contíguas, resultando em informação redundante; (b) a suscetibilidade às interferências de ruídos, o que dificulta a identificação e a quantificação de materiais; e (c) a demanda computacional para os processamentos subseqüentes. A fim de corrigir tais problemas, Green et al (1988) propuseram uma nova metodologia - MNF, adaptada para o ambiente hiperespectral, baseada na Análise por Componentes Principais (ACP) (Green et al., 1988).

A transformação MNF concilia tanto os procedimentos de segregação da componente ruído como também da maximização da variância dos dados. Em outras palavras, o objetivo é condensar as informações espectrais dos alvos, contidas em várias bandas do espectro eletromagnético, em um número reduzido de bandas transformadas, sem perda de informações, os quais o tornam uma importante fase no processamento digital para a identificação dos MRs de uma imagem. Essas transformações são realizadas pixel a pixel e não dependem da localização espacial dos dados (Carvalho Júnior et al., 2003; Moreira, 2003).

Essencialmente, a transformação MNF segue duas transformações em cascata, sendo que a primeira transformação se baseia em uma matriz de covariância estimada de ruído para remover a correlação interbandas e re-escalonar o ruído. Esta transformação resulta em um conjunto de bandas caracterizadas por variância igual. A segunda transformação consiste na transformação padrão por Componentes Principais dos dados, resultando em um novo conjunto de bandas que é ordenado segundo os autovalores (“*eigenvalues*”) que expressam a variância das bandas. A ordem crescente das componentes implica em aumento do nível de ruído, indicado pela menor variância.

Os dados resultantes da transformação MNF podem ser divididos em dois grupos: o primeiro grupo, associado aos maiores autovalores (maior variância) e imagens com pouco ruído, apresentando imagens espacialmente coerentes; e um

segundo grupo, associado às bandas MNF de maior ordem (menor variância), apresentando imagens ruidosas com autovalores próximos a unidade (ENVI, 2000). As componentes MNF do segundo grupo são dispensadas e as bandas MNF do primeiro grupo, que representam a dimensionalidade dos dados, são selecionadas para os processos subsequentes.

Os dados do sensor Hyperion, com baixo SNR, produzem autovalores menores em relação aos dados AVIRIS (Figura 2.23). Dessa forma, a dimensionalidade dos dados Hyperion é inferior, o que resulta em imagens MNF com menor variância e coerência espacial. Isto pode ser verificado pela comparação visual entre as bandas MNF apresentadas nas Figuras 2.24 e 2.25.

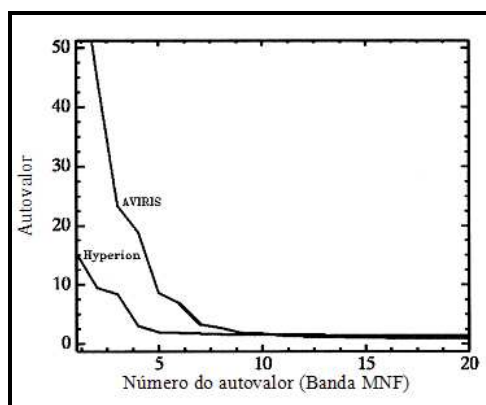


FIGURA 2.23 - Exemplos de autovalores observados pela transformação MNF para dados SWIR dos sensores Hyperion e AVIRIS, adquiridos em Death Valley, CA.
FONTE: Kruse et al. (2003)




FIGURA 2.24 - Exemplos de bandas MNF transformadas de dados SWIR do AVIRIS em Death Valley, CA. As bandas dispostas no sentido da esquerda para direita correspondem à seguinte ordem MNF: 1; 5; 8; 10 e 20.
FONTE: Kruse et al. (2003a)




FIGURA 2.25 - Exemplos de bandas MNF transformadas de dados SWIR do Hyperion em Death Valley, CA. As bandas dispostas no sentido da esquerda para direita correspondem à seguinte ordem MNF: 1; 5; 8; 10 e 20.

FONTE: Kruse et al. (2003a)

2.4.4.2 - Índice de Pureza de Pixel (PPI)

Boardman et al. (1995) desenvolveram o Índice de Pureza do Pixel (*Pixel Purity Index* – PPI) para selecionar MRs da própria imagem (membros derivados), através da determinação de um simplex n -dimensional que se ajusta aos dados da imagem. Os pixels são transformados e projetados em um vetor unitário randômico, onde, os pixels mais extremos em cada projeção são registrados, assim como o número total de vezes em que isso ocorre. Finalmente, uma imagem PPI é gerada, na qual o valor de cinza de cada pixel corresponde ao número de vezes que cada pixel foi registrado como o extremo em alguma projeção (quanto maior for o valor do pixel na imagem PPI, maior é o seu grau de pureza).

Desta forma, a partir da imagem PPI, pode-se estipular novos valores para corte utilizando a técnica de fatiamento, o que permite uma melhor seleção dos MRs da imagem. Observa-se que à medida que aumenta o valor de PPI de corte, as áreas com pixels puros tornam-se mais restritas. Esse procedimento é bastante útil na averiguação de campo, pois permite determinar a localização dos pixel puros.

2.4.4.3 – Visualizador n -Dimensional

O visualizador n -Dimensional (Figura 2.26) é uma ferramenta interativa para visualização e seleção dos MRs no espaço n -dimensional. Nessa ferramenta o espectro pode ser imaginado como pontos em um diagrama de dispersão n -dimensional, onde “ n ” é o número de bandas MNF. As coordenadas dos pontos no n -

espaço consistem de “n” valores que são os valores de radiância ou reflectância espectral em cada banda para um determinado pixel (ENVI, 2000).

Este visualizador permite ao operador rotacionar os eixos e alterná-los em diferentes combinações de bandas MNF até atingir posições que evidenciam os MRs por “pontas” ou extremidades expostas pelo diagrama (Rudorff, 2006).

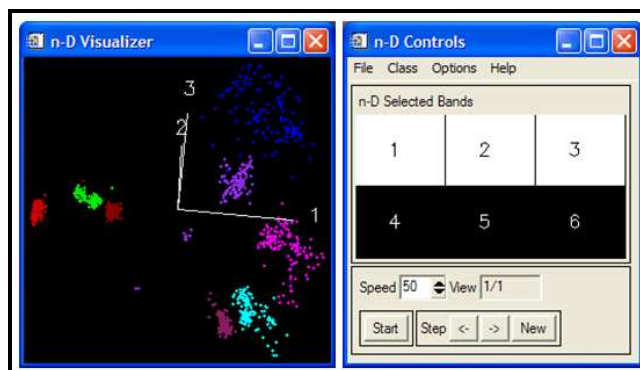


FIGURA 2.26 - Visualizador *n*-Dimensional (ENVI), que possibilita visualizar a separabilidade das classes e selecionar manualmente os MRs.

2.5 – Software VIPER (*Visualization and Image Processing for Environmental Research*) Tools

O Software VIPER Tools (Roberts et al., 2007) (Figura 2.27) foi desenvolvido com o intuito de fornecer uma ferramenta “amigável” para a aplicação do MESMA/SMA, e principalmente, como ferramenta de análise de escolha de conjuntos de MRs a partir de biblioteca(s) espectral.

É um programa de distribuição gratuita com código fonte fechado, desenvolvido em IDL (*Interactive Data Language*), que opera como extensão do ENVI. O VIPER Tools pode processar dados em número digital, radiância ou reflectância. Fatores de escala podem ser definidos, considerados os formatos numéricos e escalonamento dos dados. A unidade de saída das imagens-fração é o formato numérico de ponto flutuante.

Para facilitar a seleção dos MRs mais representativos e o desenvolvimento de bibliotecas espectrais mais eficientes para serem empregadas no MESMA/SMA,

foram implementadas no VIPER *Tools* as métricas *Count-based Endmember Selection* (CoB) (Roberts et al., 2003), *Endmember Average RMSE* (EAR) (Dennison & Roberts, 2003) e *Minimum Average Spectral Angle* (MASA) (Dennison et al., 2004), além das ferramentas necessárias para geração e edição de bibliotecas espectrais e modelos de mistura (MESMA e SMA).




FIGURA 2.27 - Janela com os menus de ferramentas implementadas no VIPER *Tools*.

O VIPER *Tools* pode ser usado em uma ampla variedade de dados nas mais diversas aplicações. No seu nível mais simples, o VIPER *Tools* pode ser utilizado para executar o MESMA/SMA a partir de bibliotecas espectrais existentes no ENVI, ou pode ser utilizado na sua forma mais completa, para construir novas bibliotecas espectrais, documentar (metadados), unir ou separar bibliotecas, selecionar MRs através das métricas nele implementadas, e aplicar os modelos MESMA/SMA (Roberts et al., 2007).

2.5.1 – Biblioteca espectral

O módulo *Create Spectral Library from ROIs* do VIPER *Tools* possibilita a geração de bibliotecas espectrais a partir de ROIs (*Region of Interest*), EVF (ENVI *Vector Files*) e outras fontes que se baseiam na imagem (Figura 2.28), armazenando o espectro de cada pixel de forma a preservar a diversidade espectral, diferentemente do ENVI que se baseia na média dos pixels para representá-los. Nesta ferramenta, os espectros de cada pixel são automaticamente extraídos e armazenados em uma

biblioteca espectral no formato ENVI (.sli). Cada espectro é nomeado com o nome do ROI de origem seguido pelas coordenadas x-y do pixel.

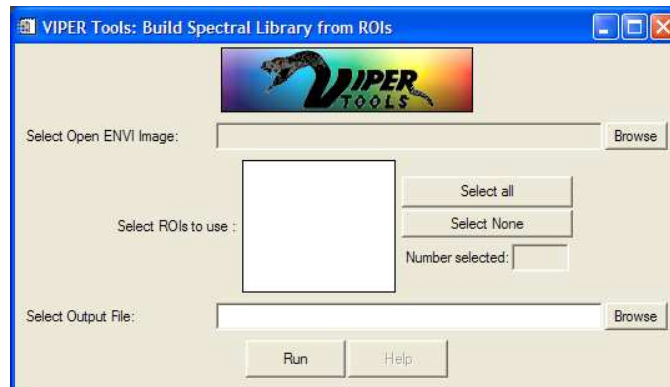


FIGURA 2.28 - Janela para seleção dos ROIs para gerar a biblioteca espectral (VIPER Tools).

Para calcular as métricas EAR, MASA e CoB de cada classe é necessário que os espectros da biblioteca estejam associados à metadados. Isso permite ao usuário estabelecer diferentes critérios de seleção e visualização. No módulo *Create Metadata for Spectral Library* os metadados são gerados e armazenados automaticamente no formato CSV (*Comma Separated Value*). A primeira coluna inclui o nome de cada espectro (ROI/EVF), com a respectiva coordenada x e y do pixel. As demais colunas são editadas a critério do usuário, podendo-se adicionar quantas colunas forem necessárias para o armazenamento de informações (p.ex., classe, espécie, localização, sensor ou um simples nome), embora o *VIPER Tools* utilize somente duas colunas como critério de separação (Figura 2.29).

	A	B	C	D	E	F	G	H	I	J	K
1	Name	Pen-imperv	Class	Form	phenology	leafform	Dominant	Percent	Source	Photo	Scale
2	EVF_1_tm_X463_Y224	pernious	gv	shrub	evergreen	broadleaf	ce-me	50-75	av010614	none	20m
3	EVF_1_tm_X464_Y224	pernious	gv	shrub	evergreen	broadleaf	ce-me	50-75	av010614	none	20m
4	EVF_1_tm_X464_Y225	pernious	gv	shrub	evergreen	broadleaf	ce-me	50-75	av010614	none	20m
5	EVF_1_tm_X465_Y225	pernious	gv	shrub	evergreen	broadleaf	ce-me	50-75	av010614	none	20m
6	EVF_1_tm_X462_Y226	pernious	gv	shrub	evergreen	broadleaf	ce-me	50-75	av010614	none	20m
7	EVF_1_tm_X463_Y227	pernious	gv	shrub	evergreen	broadleaf	ce-me	50-75	av010614	none	20m
8	EVF_1_tm_X465_Y227	pernious	gv	shrub	evergreen	broadleaf	ce-me	50-75	av010614	none	20m
9	EVF_1_tm_X465_Y227	pernious	gv	shrub	evergreen	broadleaf	ce-me	50-75	av010614	none	20m
10	EVF_2_tm_X465_Y218	pernious	gv	shrub	evergreen	broadleaf	ce-me	75-90	av010614	none	20m
11	EVF_2_tm_X466_Y219	pernious	gv	shrub	evergreen	broadleaf	ce-me	75-90	av010614	none	20m
12	EVF_2_tm_X468_Y219	pernious	gv	shrub	evergreen	broadleaf	ce-me	75-90	av010614	none	20m
13	EVF_2_tm_X470_Y219	pernious	gv	shrub	evergreen	broadleaf	ce-me	75-90	av010614	none	20m
14	EVF_2_tm_X468_Y220	pernious	gv	shrub	evergreen	broadleaf	ce-me	75-90	av010614	none	20m
15	EVF_2_tm_X469_Y220	pernious	gv	shrub	evergreen	broadleaf	ce-me	75-90	av010614	none	20m
16	EVF_2_tm_X470_Y220	pernious	gv	shrub	evergreen	broadleaf	ce-me	75-90	av010614	none	20m
17	EVF_2_tm_X471_Y220	pernious	gv	shrub	evergreen	broadleaf	ce-me	75-90	av010614	none	20m
18	EVF_2_tm_X472_Y220	pernious	gv	shrub	evergreen	broadleaf	ce-me	75-90	av010614	none	20m
19	EVF_3_tm_X507_Y201	pernious	gv	shrub	evergreen	broadleaf	ce-me	50-75	av010614	none	20m
20	EVF_3_tm_X509_Y201	pernious	gv	shrub	evergreen	broadleaf	ce-me	50-75	av010614	none	20m
21	EVF_3_tm_X500_Y202	pernious	gv	shrub	evergreen	broadleaf	ce-me	50-75	av010614	none	20m
22	EVF_3_tm_X501_Y202	pernious	gv	shrub	evergreen	broadleaf	ce-me	50-75	av010614	none	20m
23	EVF_3_tm_X505_Y202	pernious	gv	shrub	evergreen	broadleaf	ce-me	50-75	av010614	none	20m
24	EVF_3_tm_X506_Y202	pernious	gv	shrub	evergreen	broadleaf	ce-me	50-75	av010614	none	20m
25	EVF_3_tm_X508_Y202	pernious	gv	shrub	evergreen	broadleaf	ce-me	50-75	av010614	none	20m
26	EVF_3_tm_X509_Y202	pernious	gv	shrub	evergreen	broadleaf	ce-me	50-75	av010614	none	20m

FIGURA 2.29 - Arquivo .csv metadados (Excel), que possibilita a identificação e o armazenamento de informações de cada pixel.

O VIPER *Tools* ainda disponibiliza uma ferramenta (*Manage Spectral Libraries*) para auxiliar no gerenciamento de bibliotecas espectrais, possibilitando ao usuário separar ou unir bibliotecas espectrais, ordenar os espectros de uma biblioteca de acordo com sua intensidade de brilho, classes ou espécies, e qualquer outra categoria que tenha sido informada no arquivo metadados. Por exemplo, no caso em que temos duas classes de vegetação, vegetação seca e vegetação verde, e três espécies para cada classe, podemos separá-las adotando primeiramente a classe e posteriormente a espécie, desde que seja informada a qual classe e espécie os pixels pertencem (metadados).

2.5.2 - Imagens *Square Array* (RMSE, SAM, EM Fraction, Shade Fraction e Constraint Code)

As imagens *Square Array* são geradas pelo módulo “*Create Square Array*” (Figura 2.30) do VIPER *Tools* para calcular as métricas de ajustes necessárias para o cálculo do EAR, MASA e CoB. Estas imagens são armazenadas como uma imagem padrão do ENVI, $n \times n$ (onde n é o número de espectros contidos na biblioteca) contendo cinco bandas (Figura 2.30): RMSE, *Spectral Angle*, EM Fraction, *Shade Fraction* e *Constraint-Code*, que indica se o modelo utilizado satisfaz os critérios de fração e RMSE estabelecidos pelo usuário. Cada pixel da imagem *Square Array* corresponde ao espectro da coluna (eixo y) utilizado para desmisturar o espectro da linha (eixo x). Dessa forma, a diagonal possui valor “0” para todas as bandas, pois representa cada espectro modelando a si mesmo.




FIGURA 2.30 - Imagens *Square Array*. Da esquerda para direita: RMSE, *Spectral Angle*, EM Fraction, *Shade Fraction* e *Constraint-Code*.

- a) Banda RMSE: O RMSE da coluna A e linha B é a raiz do erro médio quadrático do espectro A modelando o espectro B. O RMSE é calculado pela Equação 2.4.
- b) Banda *Spectral Angle*: O *Spectral Angle* da coluna A e linha B é a distância angular, em radianos, entre o espectro A e o espectro B. Esta é a mesma métrica utilizada pela técnica SAM (*Spectral Angle Mapper*) implementada no ENVI, sendo calculada em IDL (*Interactive Data Language*) como:

$$\text{Spectral angle} = \text{acos} \left(\text{total} \left(A / \text{sqrt} \left(\text{total} \left(A^2 \right) \right) * B / \text{sqrt} \left(\text{total} \left(B^2 \right) \right) \right) \right) \quad (2.5)$$

onde A e B são vetores contendo os dados espectrais dos MRs A e B.

Para o *Spectral Angle* especificamente, a imagem será espelhada em torno da diagonal, já que o espectro A modelando o espectro B possui o mesmo ângulo espectral do espectro B modelando o espectro A.

- c) Banda EM *Fraction*: Corresponde a fração do espectro da coluna A usado para modelar o espectro da linha B. Estas imagens não são simétricas, pois as diferenças de brilho contribuem para diferenças de frações SMA e RMSE.
- d) Banda *Shade Fraction*: A fração sombra da coluna A e linha B é a fração sombra SMA do MR A utilizado para modelar o espectro B. É calculada como 1 menos a fração do MR não-sombra.
- e) Banda *Constraint Code*: Esta banda contém valores de “1” se o modelo foi parcialmente restrito (*Partially Constrained*) (as frações modeladas excederam o limite estipulado para a fração, mas não excederam o RMSE); “2” completamente restrito (*Constrained*) (se o RMSE adotado foi excedido); e “0” para modelos sem qualquer restrição (*Unconstrained*) (Figura 2.31).




FIGURA 2.31 – Exemplo de uma imagem de saída *Constraint-Code*. Pixels com valor igual a “0” estão representados em vermelho, “1” em verde e “2” em azul.

A opção “*unconstrained*” modela todos os pixels da imagem, independente se os valores resultantes de fração forem super positivos ($>100\%$) ou super negativos ($<0\%$), ou resultarem altos valores de RMSE. Neste caso, todos os valores na banda “*Constraint Code*” serão iguais a “0”. Para a opção “*Constrained*” e “*Partially Constrained*”, os valores mínimo e máximo de fração poderão estar compreendidos entre -50% e 150% , e 0% e 10% para RMSE.

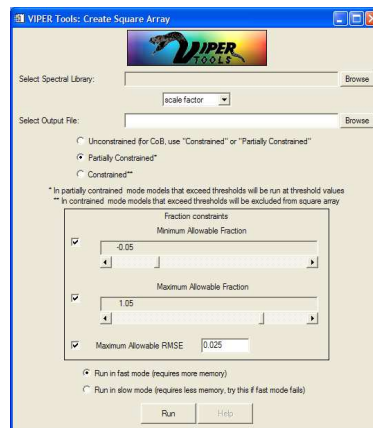


FIGURA 2.32 - Janela do *VIPER Tools (Create Square Array)* com os parâmetros de restrição de fração e RMSE.

2.5.3 - Métricas EAR, MASA e CoB

Para o cálculo das métricas EAR, MASA e CoB, o *VIPER Tools* utiliza os dados das imagens *Square Array* (RMSE, SAM, EM *Fraction*, *Shade Fraction* e

Constraint Code) para determinar qual espectro de uma classe é o mais representativo, ou seja, aqueles que melhor modelam a biblioteca espectral.

2.5.3.1 - EAR (*Endmember Average RMSE*)

EAR foi a primeira métrica proposta por Dennison & Roberts (2003a) para localizar o espectro de uma classe com o melhor ajuste. Cada espectro de uma biblioteca espectral pode ser modelado por outro espectro da biblioteca e sombra utilizando um modelo de 2 MRs. O EAR é calculado como a média RMSE produzida pelo modelo, onde, o melhor candidato será aquele que apresentar a menor média RMSE. EAR é calculado como:

$$EAR_{A,B} = \frac{\sum_{j=1}^n RMSE_{A_i, B_j}}{n-1} \quad (2.6)$$

onde A é a classe do MR, A_i é o MR, B é o espectro modelado da classe, e n é o número de espectros da classe A , e. O termo $n - 1$ representa o MR modelando a si mesmo, o qual produz RMSE zero.

Por exemplo, considere espectros que pertencem a uma classe de pinus em uma biblioteca espectral. Cada espectro de pinus seria tratado como MR do modelo utilizado para sua classe. O EAR do espectro “pinus001” seria a média RMSE de um modelo de 2 MRs, consistindo de “pinus001” e sombra, modelando todos os espectros da classe pinus. Então, o EAR é calculado para cada espectro de pinus como a média RMSE de cada espectro modelando todos os espectros da classe pinus contidos na biblioteca. O MR que apresentar o menor EAR será o mais representativo da classe.

Vale ressaltar que o EAR não fornece uma medida de “pureza”, como a técnica PPI, mas sim, uma medida de desempenho de cada MR para modelar espectros de sua própria classe. Caso a diversidade espectral intra-classe seja muito alta, o MR com menor EAR poderá representar somente alguns espectros da sua classe, ou na pior das hipóteses, não representar nenhum espectro da própria classe (Dennison & Roberts, 2003a).

2.5.3.2 - MASA (*Minimum Average Spectral Angle*)

A métrica MASA (Dennison et al., 2004) é similar à EAR, na medida em que se destina a selecionar os espectros com a melhor média de uma classe. A diferença está na medida utilizada, neste caso, o ângulo espectral. Nesta abordagem, cada espectro é utilizado para calcular o ângulo espectral entre ele e todos os outros espectros da biblioteca espectral, sendo calculado como a média do ângulo espectral entre o espectro de referência (modelo candidato) e todos os outros espectros da mesma classe.

A média do ângulo espectral para um MR modelando a sua própria classe utilizando SAM (*Spectral Angle Mapping*) (Kruse et al., 1993) pode ser calculada como:

$$\bar{\theta}_{A,B} = \frac{\sum_{j=1}^n \theta_{A,B_j}}{n-1} \quad (2.7)$$

onde A é a classe do MR, A_i é o MR, B é o espectro modelado da classe, e n é o número de espectros da classe A , e. O termo $n - 1$ representa o MR modelando a si mesmo, o qual produz θ zero.

A Figura 2.33 ilustra como as restrições de erro diferem para EAR (RMSE) e MASA (SAM), onde, o MR (A) é utilizado para modelar o espectro (B), ambos estão representados por vetores com a componente de reflexão de duas bandas espectrais. O RMSE está representado pela linha sólida, e o ângulo espectral pela linha tracejada. Para o MESMA, B é modelado como uma mistura linear de A mais sombra, representada pela origem. O espectro será modelado se o RMSE estiver dentro da área sombreada. O albedo de A pode variar, permitindo que o MR “deslize” ao longo do vetor, porém, o albedo de B é fixo. A restrição de erro RMSE é paralela ao vetor do MR, uma vez que a distância mais curta (menor RMSE) do vetor do MR, a um ponto qualquer ao longo do vetor do espectro modelado, é uma linha perpendicular ao vetor do MR. Se o espectro modelado é escuro ($B1$), então o RMSE será pequeno e poderá ser inferior a restrição de erro especificado. Se o espectro modelado é brilhante ($B2$) o RMSE será maior e poderá ultrapassar a restrição de erro. Para SAM, o albedo do

espectro modelado não importa no que diz respeito à restrição do ângulo espectral. O ângulo espectral entre A e B será o mesmo para qualquer par de pontos ao longo de A e B . Para toda a gama de albedos, não há equivalência direta entre o RMSE e restrições de erro do ângulo espectral (Dennison et al., 2004).

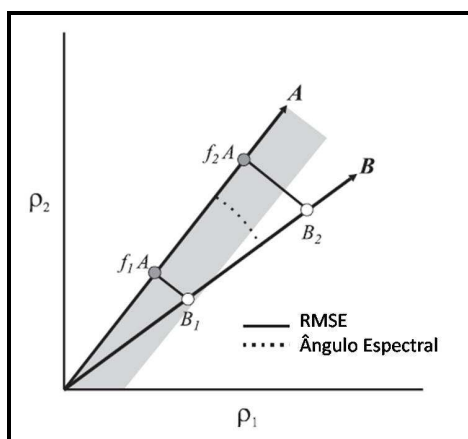


FIGURA 2.33 - Dois espectros, Membro de Referência A e o espectro modelado B , representados como vetores com componentes de reflexão de duas bandas espectrais. f representa a fração do MR A .
 FONTE: Dennison et al. (2004).

2.5.3.3 - CoB (*Count Based Endmember Selection*)

CoB foi a primeira métrica proposta por Roberts et al. (2003) como meio de selecionar os MRs mais eficientes de uma biblioteca espectral, de forma que modele o maior número de espectros de sua própria classe. Nesta abordagem, candidatos a MRs são avaliados pelos critérios de fração, RMSE e resíduo, quando decompondo outro espectro da biblioteca. Esta informação é armazenada na banda “*Constrained*”. Depois de calcular cada modelo, o número total de espectros modelados dentro da classe (in_CoB) e o número total de espectros modelados fora da classe (out_CoB) são gravados para cada modelo. O melhor modelo será aquele que possuir o maior valor “in_CoB”.

A medida “out_CoB” fornece uma medida de confusão entre as classes, na qual maiores valores sugerem significativa confusão. Em uma situação ideal, o melhor espectro é aquele que modela apenas espectros de sua classe e não modela espectros de outra (espectro especialista). Nesta situação, o modelo terá um alto “in_CoB” e um baixo “out_CoB”. Para avaliar a generalidade de um espectro, o *VIPER Tools* inclui o

Count Based Index (CoBI), que é calculado como a razão de “in_CoB” por “out_CoB” com o denominador multiplicado pelo número de espectros da classe. Assim, um espectro com alto “CoBI” e alto “in_CoB” representa uma excelente escolha como MR para o modelo de mistura. Alto “CoBI” e moderadamente baixo “in_CoB” pode ser também um bom candidato, uma vez que capta o espectro de uma classe que é espectralmente único, mesmo que não seja bem representado na biblioteca. Baixos valores de “CoBI” somente deverão ser aceitos caso possuam um alto “in_CoB” (espectro generalista⁴) (Roberts et al., 2007).

2.5.3.4 – Cálculo das métricas EAR, MASA, CoB e seleção dos MRs com melhor desempenho

Para o cálculo das três métricas, o *VIPER Tools* oferece uma interface bastante simples (Figura 2.34), onde somente é necessário entrar com a imagem *Square Array*, o atributo que separa os espectros da biblioteca em classes (no caso, coluna do arquivo de metadados da biblioteca espectral) e o nome do arquivo de saída. Após o processamento, é gerado um arquivo com extensão “emc” com os resultados numéricos. Neste caso, é possível separar os espectros pelo seu valor de brilho, visto que o *VIPER Tools* o calcula automaticamente para cada espectro contido na biblioteca espectral.

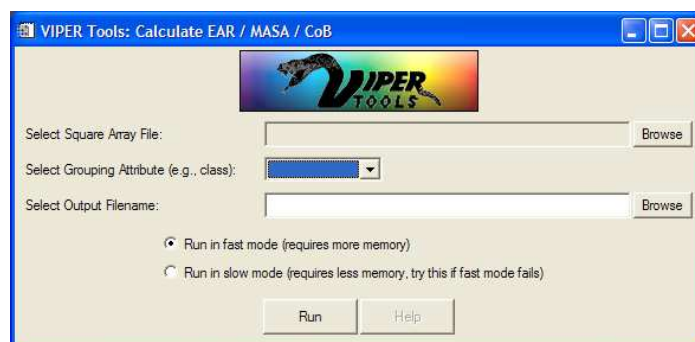


FIGURA 2.34 - Interface do *VIPER Tools* (*Calculate EAR/MASA/CoB*) para o cálculo das métricas EAR, MASA e CoB.

Por fim, para seleção dos MRs que apresentaram melhor desempenho EAR, MASA e CoB, o *VIPER Tools* oferece uma ferramenta de visualização (Figura 2.35)

⁴ Apresentam baixo RMSE ao modelarem espectros de sua própria classe e de classes distintas.

do arquivo “emc”, onde, o usuário poderá avaliar, selecionar e exportar para uma segunda biblioteca espectral, os espectros mais representativos para serem utilizados nos modelos MESMA/SMA. Os espectros podem ser visualizados em sua totalidade ou em grupos específicos (p.ex. espécies), e classificados em ordem crescente ou decrescente em qualquer uma das três métricas.

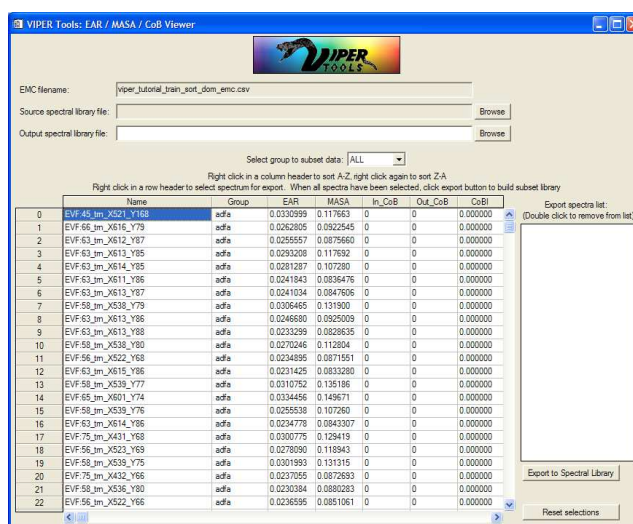


FIGURA 2.35 - Interface do VIPER Tools (EAR/MASA/COB Viewer) para seleção dos MRs com melhor desempenho. A tabela do visualizador é composta por sete colunas, incluindo o nome do espectro, o grupo, EAR, MASA, In_CoB, Out_CoB e CoBI.

2.5.4 - MESMA/SMA

O módulo *Run SMA/MESMA* (Figura 2.36) do *VIPER Tools* permite a aplicação de modelos de mistura simples (SMA), selecionando um único MR para cada biblioteca espectral de referência, ou múltiplos modelos (MESMA), com a seleção de mais de um MR por biblioteca. Para refinar o ajuste do modelo, o programa oferece alguns parâmetros de restrição, como: valores mínimos e máximos de fração da(s) componente(s) não-sombra; valor máximo de fração da componente sombra; RMSE máximo e o valor máximo do erro residual para cada banda. No caso do MESMA, será aplicado para cada pixel, o modelo que apresentar o menor valor RMSE.

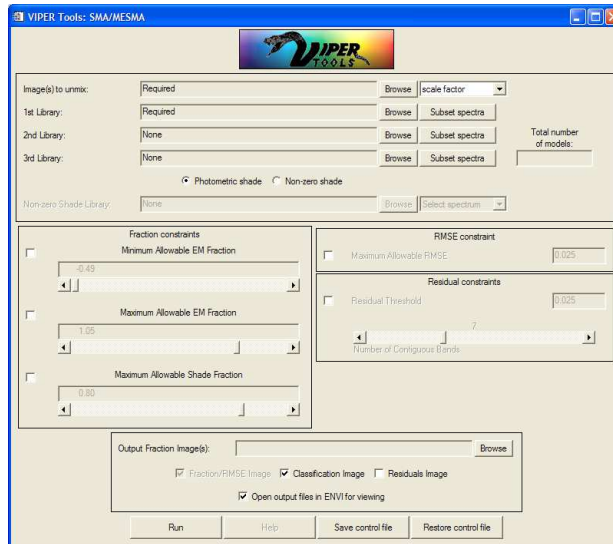


FIGURA 2.36 - Módulo *Run SMA/MESMA* do *VIPER Tools* para aplicação dos modelos de mistura SMA e MESMA.

Neste módulo, é possível selecionar até três bibliotecas espectrais, onde, o número de bibliotecas selecionadas irá determinar o número de componentes em cada modelo. Dessa forma, se apenas uma biblioteca espectral for selecionada, o(s) modelo(s) possuirá(ão) duas componentes (1 não-sombra + sombra); se duas bibliotecas forem selecionadas, o modelo terá três componentes (2 não-sombra + sombra). Por fim, se forem selecionadas três bibliotecas, o modelo terá quatro componentes (3 não-sombra + sombra).

Quanto maior o número de MRs selecionados em cada biblioteca (no caso do MESMA), maior será o número de modelos aplicados para cada pixel, o que permite representar a variabilidade espectral de um determinado material.

Para a componente sombra, o módulo disponibiliza duas opções: sombra fotométrica, segundo a qual a sombra-padrão corresponde à reflectância igual a zero; e a sombra não fotométrica, que permite ao usuário fornecer o espectro de sombra de uma biblioteca espectral. Em geral, nessa abordagem, é utilizado um espectro de água limpa como uma aproximação daquele de sombra (Fuckner, 2008). Um mesmo modelo pode ainda ser utilizado para o processamento de mais de uma imagem ao mesmo tempo.

2.5.5 - Imagens fração (*EM Fraction, Shade Fraction, RMSE e Modelo*)

As imagens fração representam as proporções (abundância) dos componentes na mistura espectral, representados em ND (número digital). Quanto maior o ND do pixel, maior será a proporção de um determinado componente .

Segundo Ponzoni & Shimabukuro (2007), as imagens fração podem ser consideradas como uma forma de redução da dimensionalidade dos dados e também como uma forma de realce das informações. Além disso, o modelo transforma a informação espectral em informação física (valores de proporção das componentes no pixel). A imagem fração vegetação realça as áreas de cobertura vegetal; a imagem fração solo realça as áreas de solo exposto; enquanto que a imagem fração sombra/água realça as áreas ocupadas com corpos d'água (rios, lagos, etc.) e também áreas de queimadas, áreas alagadas, etc. Normalmente são geradas imagens fração de vegetação, solo e sombra/água, pois geralmente estão presentes em qualquer cena terrestre.

O módulo *Run SMA/MESMA*, descrito anteriormente, gera uma imagem fração para cada componente não-sombra (Figura 2.37), onde o número de imagens fração será igual ao número de bibliotecas selecionadas (uma a três); e uma imagem fração para a componente sombra (padrão para todos os modelos) (Figura 2.38). Também gera uma imagem contendo o número do modelo utilizado (MESMA), o RMSE produzido pelos modelos (Figura 2.38) e um arquivo metadado (formato CSV), que reporta os parâmetros de entrada e saída dos MRs e a proporção da imagem que foi modelada por cada modelo (satisfeito os critérios de fração, RMSE e residual). Também há a possibilidade de incluir uma imagem “classificada” (Figura 2.39), onde, para cada modelo utilizado, é atribuída uma cor, e uma imagem com os valores dos resíduos do modelo para cada banda.



FIGURA 2.37 - Exemplo de imagens fração resultante de um modelo com quatro MRs (GV+NPV+Solo+Sombra). Da esquerda para direita: Imagem fração vegetação verde (GV), imagem fração vegetação seca (NPV) e imagem fração solo.

FONTE: Adaptada de Roberts et al. (2007).




FIGURA 2.38 - Da esquerda para direita: Imagem fração sombra, RMSE e imagem residual da banda 19 (548 nm).

FONTE: Adaptada de Roberts et al. (2007).




FIGURA 2.39 - Da esquerda para direita: Imagem classificada - cada modelo (MESMA) é representado por uma cor; Composição RGB das imagens fração (NPV, GV, solo); imagem (AVIRIS) de entrada para o modelo.

FONTE: Adaptada de Roberts et al. (2007).

CAPÍTULO 3

ÁREA DE ESTUDO

A área de estudo está inserida na Planície Costeira do Rio Grande do Sul, porção nordeste do Estado do Rio Grande do Sul, compreendendo parte dos municípios de Tramandaí, Imbé, Osório, Xangri-Lá e Maquiné, entre as coordenadas geográficas de 29°46'28,04"; 29°47'25,10"; 30°0'59,07" e 30°1'55,75" de latitude sul, e 50°11'9,96"; 50°6'26,42"; 50°15'4,57" e 50°10'18,02" de longitude oeste (Fig. 3.1), totalizando uma área retangular de 7,68 por 27 km.

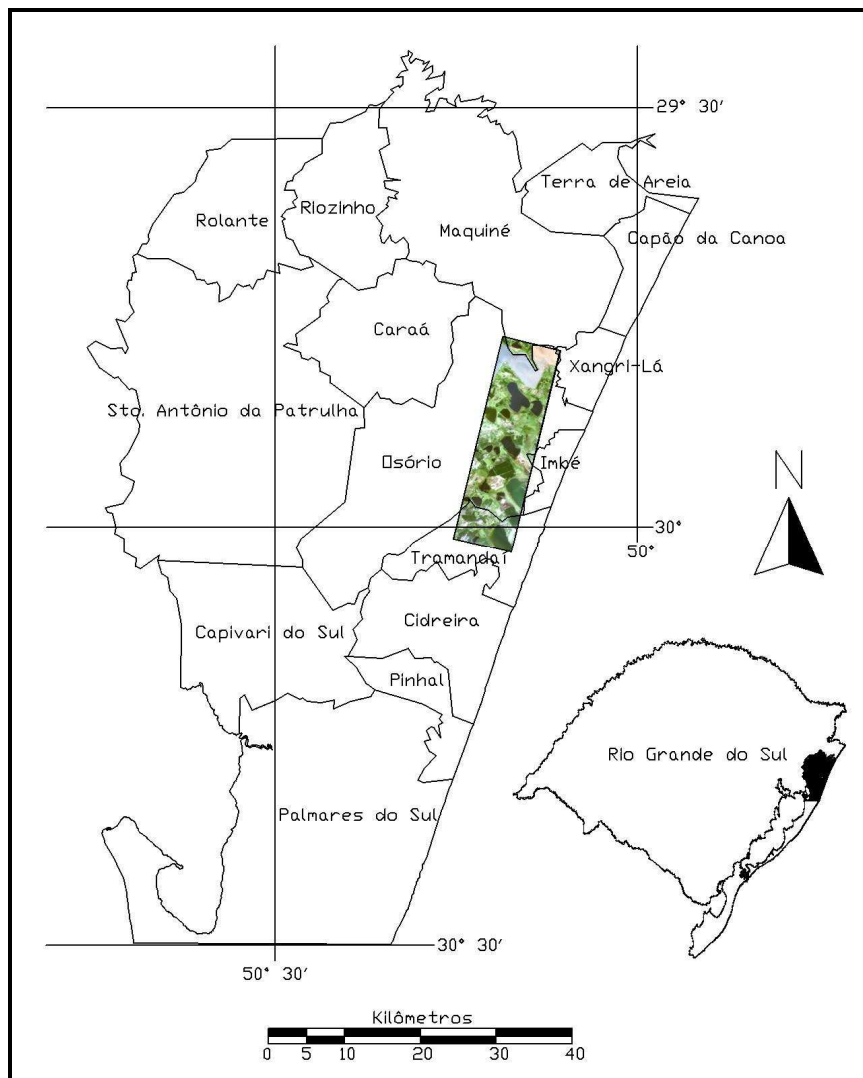


FIGURA 3.1 - Localização da área de estudo.

A seguir são descritas algumas características físicas da área de estudo.

3.1 - Aspectos Geomorfológicos

A Província Costeira do Rio Grande do Sul (Villwock & Tomazelli, 1995) é constituída pela porção emersa da Bacia de Pelotas, uma bacia marginal da Plataforma Sul Americana que é composta de sedimentos continentais, transicionais e marinhos, desenvolvidos a partir da abertura do Atlântico Sul no Cretáceo. A porção superficial desta seqüência sedimentar está exposta na Planície Costeira do Rio Grande do Sul.

Neste contexto geomorfológico, a área de estudo situa-se ao norte da Planície Costeira do Rio Grande do Sul, tendo seu limite noroeste próximo à cidade de Osório, bem delineada pela escarpa do Planalto, na Serra Geral, borda da Bacia Sedimentar do Paraná e sudoeste, interdigitada com a Depressão Central na altura do paralelo 30°S.

Ao longo da área observa-se uma série de lagos, lagoas e outros corpos d'água pequenos presentes na faixa arenosa, característica marcante em toda a extensão dos 700 Km da Planície Costeira. São identificadas 23 lagoas, a saber: Negra, Malvas, Palmital, Pinguela, Lessa, Caieira, Traíras, Caconde, Rincão, Pombas, Rincão, Inácio, Tramandaí, Armazém, Biguá, Emboaba, Custódio e Tapera e outras menores sem nomes definidos.

A faixa arenosa desta planície é formada por sedimentos clásticos provenientes da dissecação das áreas mais altas como Planalto e Escudo Sul Rio-grandense sob a ação dos processos de erosão pelos ventos, ondas, correntes e variações do nível do mar, e posteriormente, se acumularam numa grande variedade de ambientes deposicionais continentais, transicionais e marinhos.

Villwock (1984) & Villwock et al. (1986) propõem o modelo de compartimentação geomorfológico, mencionando que as quatro grandes mudanças no nível do mar e atividades dos ventos resultaram numa série de depressões ocupadas por lagunas, lagoas e lagos, e acumulações de areia formando cordões de dunas paralelas à costa. Associadas ao clímax dos quatro eventos trans-regressivos do nível do mar, formaram-se os Sistemas Depositionais Laguna-Barreira. Os Sistemas Depositionais Laguna-Barreira I, II e III formaram-se durante o Pleistoceno, e o

Sistema Depositional Laguna-Barreira IV, ainda ativa, durante o Holoceno, conforme o perfil esquemático abaixo:




FIGURA 3.2 – Perfil esquemático (W –E) transversal aos sistemas deposicionais da Planície Costeira do Rio Grande do Sul com suas fácies sedimentares associadas.
FONTE: Adaptada de Tomazelli & Villwock (2005).

Considerando o modelo de Sistemas de Laguna- Barreira polifásico, somente os dois últimos eventos trans-regressivos do Pleistoceno Superior (Laguna-Barreira III) e do Holoceno (Laguna-Barreira IV) são aplicáveis na área em questão, originando feições geomorfológicas como áreas de terraços marinhos, que inclui planícies fluviais, lacustres e paludais, depósitos de canais fluviais e inter-lagunares, dunas de margem lagunar, deltas flúvio-lagunares, lagos colmatados (banhados) e cristas de praia lagunar (Villwock & Tomazelli, 1995).

Estes ambientes coexistem lado a lado interdigitados entre si e sua evolução é controlada principalmente pelas variações do nível do lençol freático que acompanharam as flutuações do nível relativo do mar. Observa-se freqüentemente o progressivo avanço da vegetação marginal dos corpos aquosos e os sedimentos trazidos pelos cursos fluviais e a migração das dunas eólicas que avançam pela encosta leste destes ambientes.

3.2 - Aspectos Geológicos

Conforme o Mapa Geológico da Província Costeira do Rio Grande do Sul (Figura 3.3) (Villwock & Tomazelli, 1995), a área em questão compreende as seguintes seqüências sedimentares originárias dos dois últimos eventos de mudanças do nível do mar decorridas no Quaternário: Sistema Depositional Laguna-Barreira IV e Sistema Depositional Laguna-Barreira III.

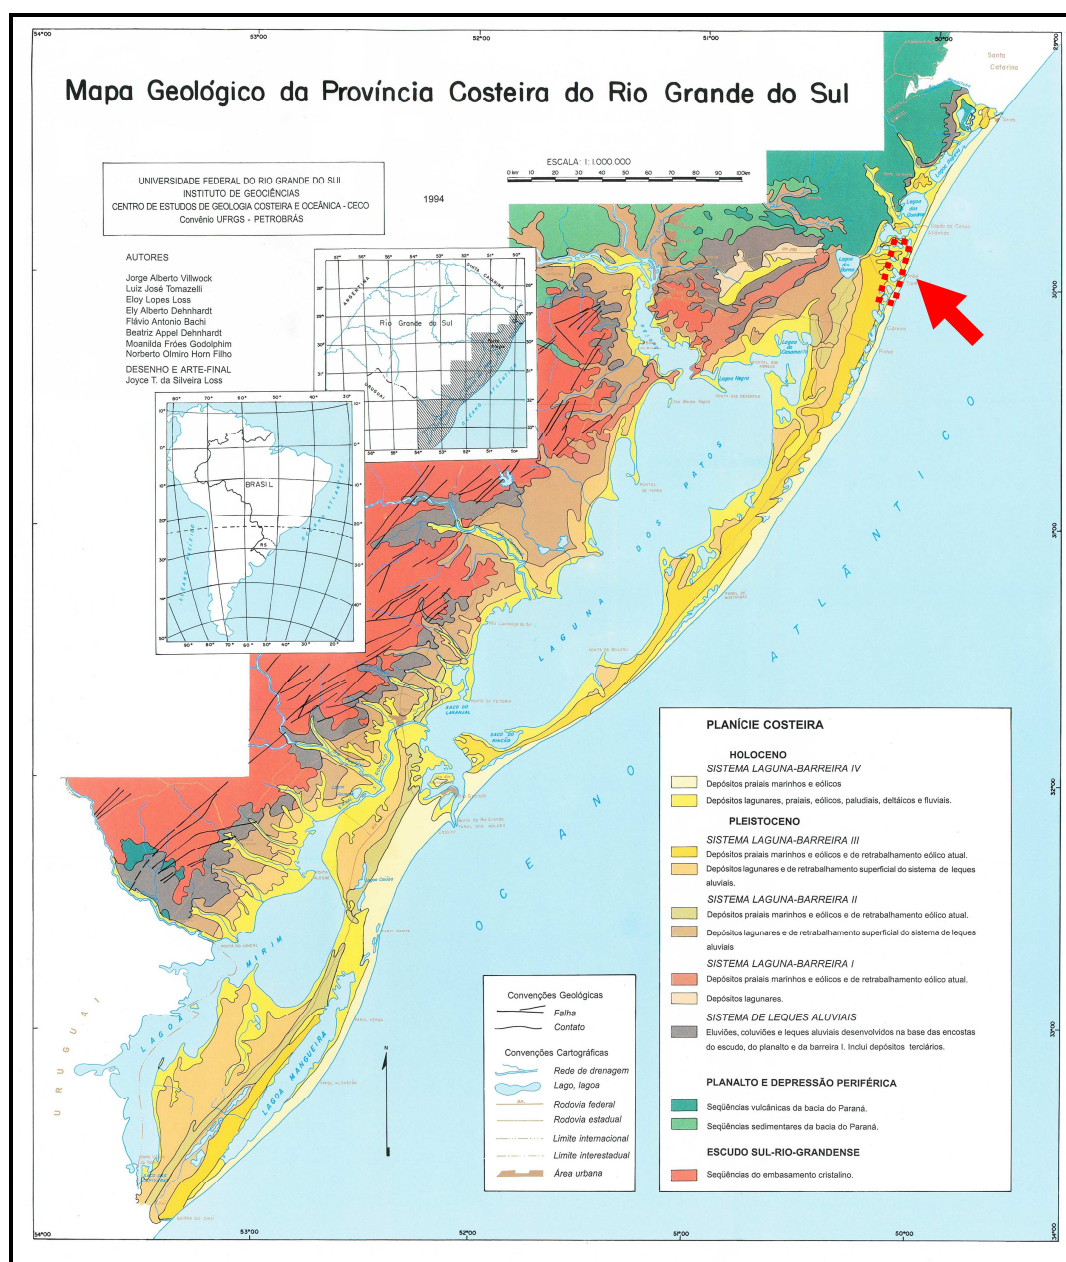


FIGURA 3.3 – Mapa de situação da Província Costeira do Rio Grande do Sul e áreas adjacentes. O retângulo em vermelho destaca a área de estudo.

FONTE: Adaptada de Villwock & Tomazelli (1994).

O Sistema Depositional Laguna-Barreira III, associado a um evento transgressivo-regressivo pleistocênico, se encontra muito bem preservado no presente e seu desenvolvimento, responsável pela implantação final do Sistema Lagunar Patos-Mirim, foi de fundamental importância na evolução geológica da Província Costeira do Rio Grande do Sul.

Os depósitos relacionados à Barreira III se estendem entre as Lagoas do Lessa, Traíra Caconde e Pombas na área. Continuando em direção sul da cidade de Osório. Estes depósitos se encontram apoiados na base da escarpa da Serra Geral, onde se interdigitam com depósitos de encosta pertencentes ao Sistema de Leques aluviais. Essa é uma indicação que no pico transgressivo da Barreira III a linha de costa atingia diretamente a escarpa da Serra Geral.

Esta barreira é constituída por fácies arenosas interpretadas como sendo de origem praial e marinho raso, recobertas por depósitos eólicos, dispostas numa sucessão vertical claramente indicativa de um processo regressivo. Os sedimentos praias são compostos por areias quartzosas claras e finas, com estratificações bem desenvolvidas que incluem a laminação plano-paralela com truncamentos de baixo ângulo e as cruzadas planar e acanalada. As areias eólicas de cobertura apresentam uma coloração mais avermelhada e um aspecto maciço representando as dunas.

No Sistema Lagunar III, os depósitos acumulados são representados por areias finas, siltico-argilosas, pobremente selecionadas, de coloração creme, com laminação plano-paralela e incluindo concreções carbonáticas e ferruginosas. Esta seqüência não está presente na área de estudo.

Por último, identifica-se o sistema deposicional do tipo laguna-barreira da Planície Costeira, o Sistema Depositional Laguna-Barreira IV, que se desenvolveu durante o Holoceno como consequência da última grande transgressão pós-glacial. Nesta seqüência sedimentar, somente o Sistema Lagunar se faz presente predominantemente em toda porção leste da área, interdigitando os depósitos da Barreira III na porção central da área.

O Sistema Lagunar IV é constituído por um conjunto de ambientes deposicionais que incluem: corpos aquosos, costeiros (lagos e lagunas), sistemas aluviais (rios meandantes e canais inter-lagunares), sistemas deltaicos (deltas flúvio-lagunares e deltas de “maré lagunar”) e sistemas paludais (pântanos, alagadiços e turfeiras). São formadas por areias siltico-argilosas, siltes e argilas.

As areias praias da Barreira IV são quartzosas, de granulação fina a muito fina e em alguns locais apresentam elevadas concentrações de minerais pesados. O campo de dunas eólicas é bem desenvolvido, se estendendo ao longo de toda costa. Este não se visualiza na imagem da área. Porém, em virtude dos ventos provenientes do NE, as dunas livres migram no sentido SW, transgredindo terrenos mais antigos e avançando para dentro dos corpos lagunares como Tramandaí, Armazém e Lagoa das Custódias, no sudeste da área.

As seqüências vulcânicas da Formação Serra Geral e rochas sedimentares da Formação Botucatu fazem parte da Bacia do Paraná de idade Juro-Cretáceo. Estas unidades não estão presentes na área, porém são áreas fontes principais dos sedimentos da planície.

3.3 - Solo

Na parte de sedimentos recentes, os solos desta região são dunas. Nos terrenos pleistocênicos e banhados internos têm-se solos com as seguintes características (Brasil, 1973):

- Curumim: solos arenosos, quartzosos, profundos, hidromórficos, areias quartzosas hidromórficas;
- Tuia: solos com horizonte B-textural, argila de atividade baixa, não hidromórfico, podzólicos, vermelho-amarelo, abrupção, textura média, relevo suavemente ondulado, substrato sedimentos costeiros arenosos;
- Itapeva: solos pouco desenvolvidos, argila de atividade alta, hidromórficos, gley húmico, textura argilosa, relevo plano, substrato sedimentos costeiros;

- Osório: solos arenosos, quartzosos, profundos, não hidromórficos, areias quartzosas, distróficos, relevo suavemente ondulado e substrato de sedimentos recentes costeiros.

Quanto ao uso do solo, os adequados para culturas semi-permanentes ou arroz representam a maior superfície (31%). Os solos pastoris e os não produtivos e aptos para recreação correspondem ambos a 23% e os solos florestais representam 22%. Os solos aptos para culturas anuais não alcançam 2%.

3.4 - Vegetação

A vegetação primitiva nesta região da Planície Costeira, segundo Rambo apud Brasil (1973), é composta por gramíneas, ciperáceas, umbelíferas, entre outras.

Na orla das lagoas, em terrenos secos, as sociedades arbustivas constituem-se de capões, cujas copas baixas são domadas por gerivás e figueiras. Em terrenos pantanosos desenvolvem-se matas brejosas de crista de galo, touceiras de gravatás, gerivás e figueiras. Na beira seca dos capões e das matas brejosas estendem-se vassouras vermelhas e compostas arbustivas. Em campo aberto, observam-se espécies de louro e cedro, primeiros representantes da flora silvática da serra, e malhas de butiá espalhadas.

Na área da costa, em especial nas dunas, observam-se várias espécies de gramíneas. Estas, quase sempre emitindo longos estolões subterrâneos na intenção de revestir toda a duna de uma rede fixadora, da qual, de espaço em espaço, brotam as suas touceiras. Por suas touceiras possuem folhas que facilmente se esquivam do vento e pela sua tendência natural de se constituírem em sociedades rasteiras, as gramíneas são capazes de se adaptar ao efeito físico do vento.

A ação do vento influencia as espécies de vegetação a conservarem-se baixas, de folhas compridas, estreitas e tenazes, ou no caso dos arbustos, possuem os galhos duros e as folhas resistentes à dilaceração. Outros vegetais evitam o contato com o vento deitando-se no chão e formando sociedades fechadas onde o vento perde seu

efeito. Em áreas das dunas onde a ação do vento é mais calma e há maior umidade, florescem espécies rasteiras de verbenáceas e leguminosas. Apenas na zona das dunas fixas podem-se observar arbustos. Mesmo assim, a copa dos exemplares mais isolados aparece sempre deformada pelo vento. Pode-se assim dizer que a massa principal da vegetação puramente arenícola pertence às gramíneas (*Panicum reptans* e *Spartina*).

Na zona dos olhos-de-água (incluindo a das lagoas e marginais), a vegetação é completamente diferente das dunas. Os leitos são revestidos por um denso tapete de algas verdes e as gramas, juncos, verbenáceas e leguminosas rasteiras dominam nas zonas marginais.

Na parte central das lagoas, sempre de pouca profundidade, existem unicamente as algas filamentosas que, numa observação aérea do local, conferem desenhos matizados de verde e azul ao aspecto monótono das águas. Na zona marginal brejosa domina a vegetação palustre, tipos inteiramente flutuantes como os aguapés.

Na zona do campo, a vegetação se caracteriza por uma planície de cor cinzento-verde. Formam um pasto seco e magro, com uma cobertura vegetal rala e baixa formada principalmente por gramíneas e outras famílias com representantes rasteiros ou subarbustivos, deixando transparecer por toda parte a areia. Encontram-se ali, entre outras, as gramíneas comuns dos campos rio-grandenses, como *Andropogon lucostachyus*, *Cenchrus tribuloides*, *Paspalum*.

Já em campo aberto, apresentam-se espécimes de louro e cedro, primeiros representantes da flora silvática da serra, além de exemplares isolados de figueira e gerivás e milhares de butiás espalhados. Entre as árvores plantadas, notam-se quadros de eucalipto (*Eucalyptus sp.*), pinus (*Pinus ellioti*), filas de casuarinas e exemplares isolados *Tamarix gallica*.

3.5 - Clima

A Planície Costeira do Rio Grande do Sul apresenta um clima mesotérmico brando, superúmido, sem estação seca. A região caracteriza-se pela alta umidade

relativa, raramente inferior a 80% e pelos ventos constantes que sopram normalmente do NE com velocidades de 11 a 18 Km/h. Apresentam-se ocasionalmente, ventos fortes de SE que podem alcançar velocidades de até 100 km/h, com graves prejuízos à navegação e construção.

Segundo Rambo (1994), o clima dessa região pertence à cinta subtropical de variedade “sempre úmida”, com verões quentes e invernos mitigados, e ausência de períodos de seca nitidamente localizados. A temperatura média anual oscila entre 16 e 20°C. A média do mês mais quente fica entre 22 e 26°C e a média do mês mais frio entre 10 e 15°C. A precipitação pluviométrica anual varia entre 1000 e 1500 mm.

CAPÍTULO 4

MATERIAIS E MÉTODOS

Os materiais e programas computacionais utilizados para o desenvolvimento desta pesquisa estão relacionados abaixo de acordo com as etapas seguidas na Figura 4.1. A seqüência metodológica está indicada no fluxograma da Figura 4.1. e será descrita no decorrer deste capítulo.

a) Levantamento de campo:

Programa GPS *Track Maker* PRO;
GPS 76 MAP Garmin;
Cartas topográficas da área de estudo, escala 1:50.000;
Câmera digital SONY, resolução 4 MP;
Imagem Hyperion da área de estudo;
Notebook HP Pentium IV 2Ghz, RAM 1Gb, HD 120Gb.

b) Pré-processamento de imagem:

Programa ENVI 4.3;
Programa Hyperion *Tools*;
Programa FLAASH;
Programa *Global Mapper*;
Imagem GeoCOVER da área de estudo;
Desktop Pentium III 2 Ghz, RAM 1Gb, HD 80Gb.

c) Processamento de imagem e modelos de mistura SMA e MESMA:

Programa ENVI 4.3;
Programa VIPER *Tools* 1.4;
Programa Microsoft Office Excel 2003;
Desktop Pentium III 2 Ghz, RAM 1Gb, HD 80Gb.

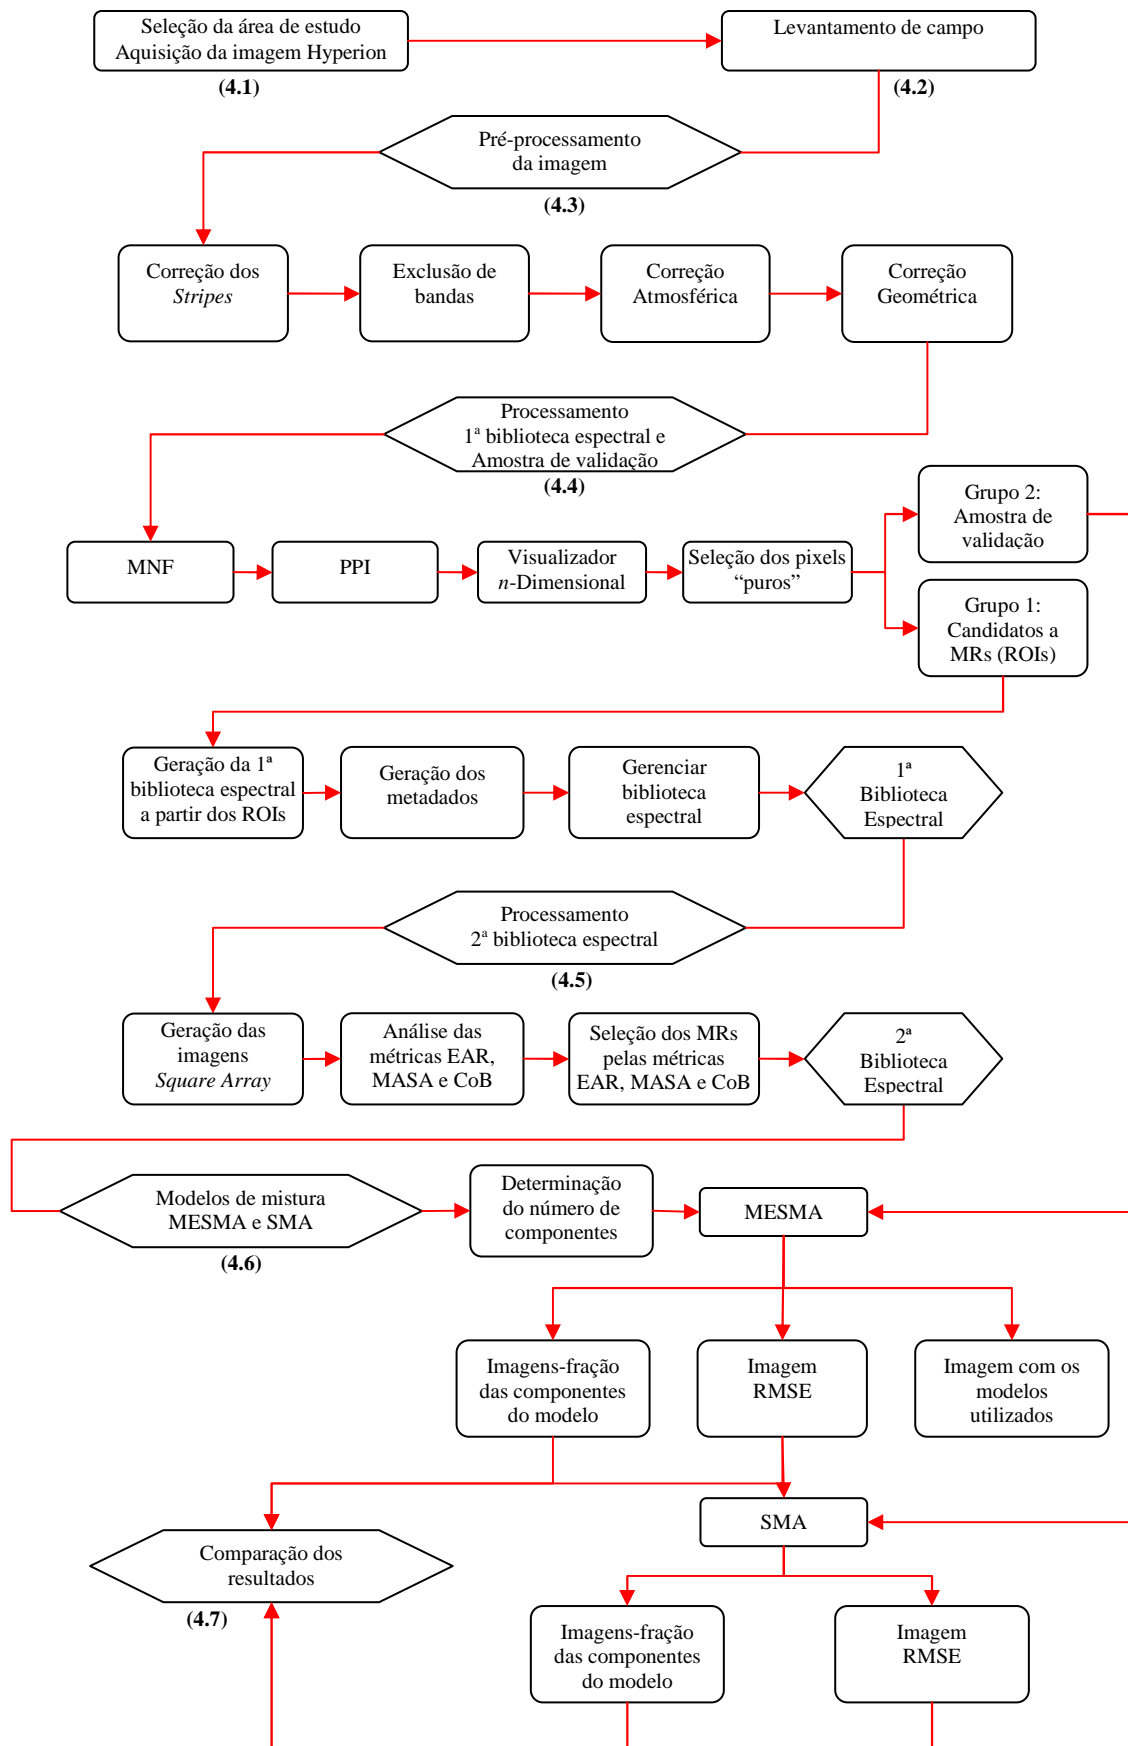


FIGURA 4.1 - Metodologia de trabalho.

4.1 - Seleção da Área de Estudo e Aquisição da Imagem Hyperion

A área de estudo (7,68 x 27 km) compreende um recorte de uma imagem Hyperion (Tabela 4.1), cuja escolha deveu-se ao fato de apresentar diversidade de alvos (dunas, cobertura vegetal e corpos d'água) com diferentes comportamentos espectrais. Outro fator muito importante foi a baixa cobertura de nuvens (< 10%) na época da aquisição da imagem.

Para a realização desta pesquisa, optou-se por utilizar uma imagem Hyperion de acervo (Tabela 4.1) devido ao prazo de entrega para aquisição programada, além de não possuir garantia quanto à cobertura de nuvens. Todo o processo de seleção e aquisição da imagem foi realizado através do visualizador USGS *Global Visualization Viewer* (<http://glovis.usgs.gov/>) (Figura 4.2). Após a finalização do pedido, os dados foram recebidos no formato HDF (*Hierarchical Data Format*) via FTP (*File Transfer Protocol*), contendo os arquivos de imagem (.L1R), metadado (.met) e header (.hdr).

Nome do arquivo	EO1H2200802004123110PZ_HGS_01
Órbita Ponto	220/080
Nível de correção	L1R
Intervalo	BIL
Colunas	256 (7,68 Km)
Linhas	3352 (100,56 Km)
Coordenada central	-29,733300; -50,133300
Data de aquisição	02/05/2004
Bandas	242

TABELA 4.1 - Características da imagem Hyperion adquirida.

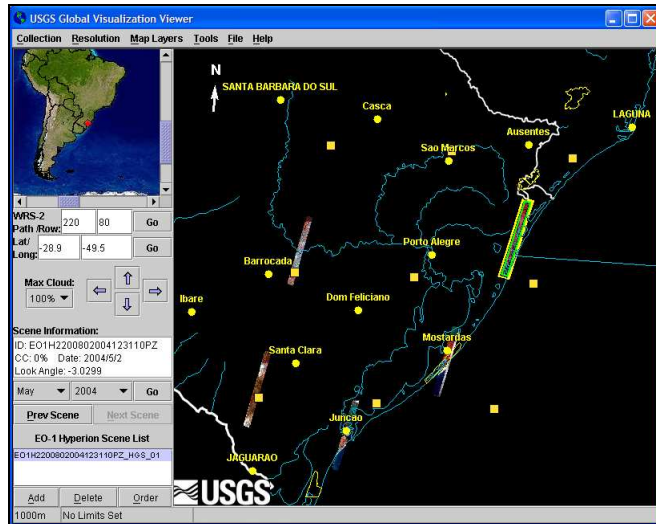


FIGURA 4.2 - Seleção para aquisição da imagem Hyperion em acervo utilizando o USGS *Global Visualization Viewer*.

4.2 – Levantamento de Campo

Para verificar os tipos de materiais existentes na cena e o quanto foram alterados desde a aquisição da imagem, por fatores antrópicos ou naturais, foram realizadas duas verificações *in situ* em 2007. Uma das campanhas foi realizada em mês similar ao de aquisição da imagem (30 de maio).

O reconhecimento dos alvos foi realizado com auxílio de um GPS (*Global Positioning System*) de navegação Garmin GPS MAP 76S conectado ao programa de navegação GPS *Track Maker* (Figura 4.3), para navegação em tempo real, sobre a imagem Hyperion.

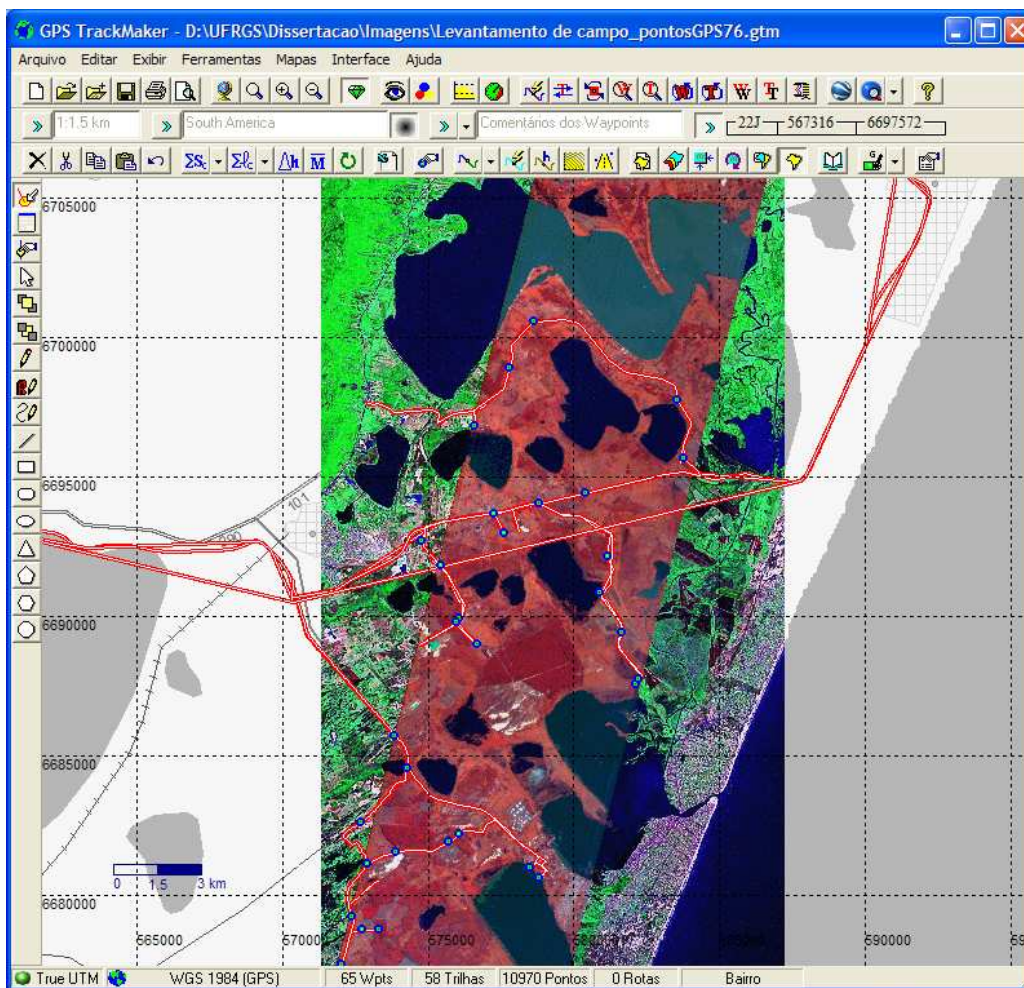


FIGURA 4.3 - Reconhecimento dos alvos imageados com o auxílio do programa para navegação em tempo real *GPS Track Maker* (Imagem Hyperion sobreposta à imagem GeoCover).

4.3 - Pré-Processamento dos Dados HYPERION

4.3.1 - Correção dos *Stripes*

Para correção dos *stripes* (Figura 4.4) foi utilizado o módulo *Hyperion Tools* (Devin White, 2007) (Figura 4.5). Este módulo é distribuído gratuitamente (<http://www.itvis.com>) e funciona como *plug-in* do ENVI. Para remoção dos *stripes*, o programa atribui ao pixel anômalo, a média do valor dos pixels da primeira coluna, de ambos os lados. Este módulo também define os intervalos nominais de comprimentos de onda das bandas, por meio do *full-width half-maximum* (FWHM); as bandas sem dados e um arquivo no formato texto (.txt), contendo o fator de escala de cada banda (parâmetro necessário para correção atmosférica no FLAASH). O

módulo também oferece uma opção para georreferenciar a imagem, utilizando as coordenadas dos vértices superiores e inferiores, disponibilizadas no arquivo metadados (.MET).



FIGURA 4.4 - *Stripes* na banda 11 (454,63 nm).

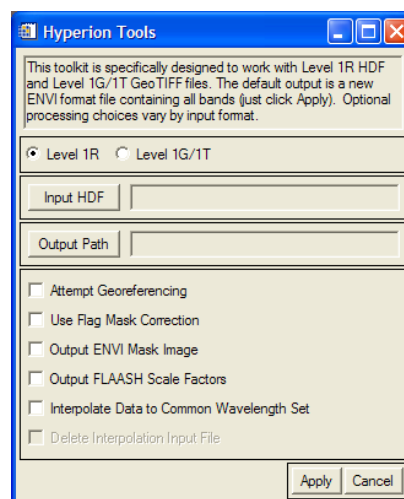


FIGURA 4.5 - Módulo *Hyperion Tools* (Devin White, 2007).
FONTE: ITTVIS (2007).

4.3.2 – Exclusão de Bandas

Das 242 bandas originais do Hyperion, apenas 196 são radiometricamente calibradas. Dentre essas 196 bandas, algumas estão posicionadas em intervalos de forte absorção por vapor de água da atmosfera em torno de 1400 e 1900 nm. Mesmo após a correção atmosférica, os dados dessas bandas não são úteis devido ao elevado nível de ruído.

Em função disso, utilizou-se no presente trabalho um total de 143 bandas para fins de análise de dados. As bandas excluídas estão relacionadas na Tabela 4.2.

VNIR	Banda	Comprimento de onda (nm)
(37 bandas)	1 - 10	355.59 - 447.17
	58 - 70	935.58 - 1057.68
SWIR	71 - 81	851.92 - 952.82
	98 - 100	1124.28 - 1144.48
	120 - 134	1346.25 - 1487.53
	165 - 182	1800.29 - 1971.76
	184 - 187	1991.96 - 2022.25
	190	2052.45
	219 - 242	2345.11 - 2577.08

TABELA 4.2 - Bandas Hyperion excluídas dos dados originais do produto L1R.

4.3.3 – Correção Atmosférica

A conversão da imagem Hyperion de valores de radiância para reflectância de superfície foi realizada com o aplicativo FLAASH. O algoritmo se baseia no modelo de transferência radiativa MODTRAN 4, que minimiza os efeitos de espalhamento e absorção causados por aerossóis e gases atmosféricos.

Os parâmetros utilizados no FLAASH para fins de correção atmosférica estão relacionados na Tabela 4.3.

Coordenada central (Lat.; Long.)	29.7333° S ; 50.1333° W
Altitude do sensor	705 Km
Elevação média do terreno	0,02 Km
Tamanho do pixel	30 m
Data aquisição	02/05/2004
Hora aquisição	13:01:58
Modelo atmosférico	<i>Mid-Latitude Summer</i>
Banda absorção vapor d'água	820 nm
Modelo de aerosol	Rural
Visibilidade da atmosfera	60 Km

TABELA 4.3 - Parâmetros utilizados para correção atmosférica no FLAASH.

O valor da elevação média foi obtido pela média dos valores das cotas altimétricas da carta topográfica de Tramandaí e Cidreira, escala 1:50.000 , folhas:

- 1) SH-22-X-C-V-4 (MI-2792/4);
- 2) SH-22-Z-A-II-4 (MI-2989/4);
- 3) SH-22-Z-A-II-2 (MI-2989/2).

O parâmetro de visibilidade foi inicialmente calculado pelo programa, sendo depois reajustado até que os espectros de reflectância resultantes do modelo fossem coerentes com o comportamento espectral tipicamente conhecido de alguns alvos, como solo, vegetação e água.

4.3.4 – Correção Geométrica

Para a correção geométrica da imagem foi utilizada uma imagem GeoCover (Landsat 5 TM) como referência. Estas imagens são disponibilizadas gratuitamente (<https://zulu.ssc.nasa.gov/mrsid/>) orto-retificadas e com resolução espacial de 28,5 m. Os pontos de controle utilizados para correção são mostrados na Figura 4.6.




FIGURA 4.6 - Seleção dos pontos de controle utilizando imagem GeoCover como referência. a) Imagem GeoCover (Landsat 5 TM / RGB: 3-2-1); b) Imagem Hyperion (RGB: 19-10-2) da área de estudo.

Os pontos de controle foram selecionados de modo que abrangessem toda a imagem e em locais de fácil identificação, como vértices de talhões, cruzamentos de estradas, pontes e canais. Segundo Crósta (1992), o procedimento usualmente adotado envolve a identificação de, no mínimo, 6 a 10 pontos de controle em uma imagem de 1.000 x 1.000 pixels, lembrando que a imagem Hyperion a ser corrigida possui 256 x 900 pixels. Após a seleção, aplicou-se sobre o conjunto de pontos um ajuste polinomial de segunda ordem, seguido pela reamostragem dos pixels da cena Hyperion pelo método de vizinho mais próximo, de forma a preservar ao máximo a informação espectral.

4.4 – Primeira Biblioteca Espectral e Amostras de Validação a partir dos Dados Hyperion

Esta etapa teve como objetivo gerar dois grupos de pixels puros (MRs) a partir dos dados Hyperion (membros derivados). O primeiro grupo deu origem à biblioteca espectral, e foi utilizado para compor os modelos MESMA e SMA. O segundo grupo foi selecionado, exclusivamente, para posterior avaliação dos resultados dos modelos MESMA e SMA, sendo por esse motivo, denominado Amostra de Validação.

Para seleção dos candidatos a MRs (Grupo 1) que deram origem a primeira biblioteca espectral, foram empregadas duas seqüências de processamentos:

- a) A primeira delas, que corresponde a seqüência descrita por Boardman & Kruse (1994) (Figura 4.7) e encontra-se implementada no Programa ENVI, foi utilizada para identificação dos pixels “puros”, candidatos a MRs. Essa metodologia envolveu a aplicação seqüencial das técnicas MNF, PPI e Visualizador *n*-Dimensional sobre os valores de reflectância de superfície das 143 bandas (VNIR e SWIR) do sensor Hyperion.
- b) A segunda e última seqüência, que corresponde ao processo descrito por Roberts et al. (2007), foi utilizada para geração de bibliotecas espectrais a partir de ROIs, criação e edição do arquivo metadados e gerenciamento de bibliotecas espectrais. Essa seqüência envolveu a aplicação em cascata dos módulos *Create Spectral Library from ROIs*, *Create Metadata for Spectral Library* e *Manage Spectral Libraries*, implementados no Programa VIPER Tools.

O segundo grupo de pixels “puros” (amostra de validação – Grupo 2) foi obtido através da primeira seqüência descrita, que envolveu somente a aplicação seqüencial das técnicas MNF, PPI e Visualizador *n*-Dimensional (Figura 4.7).

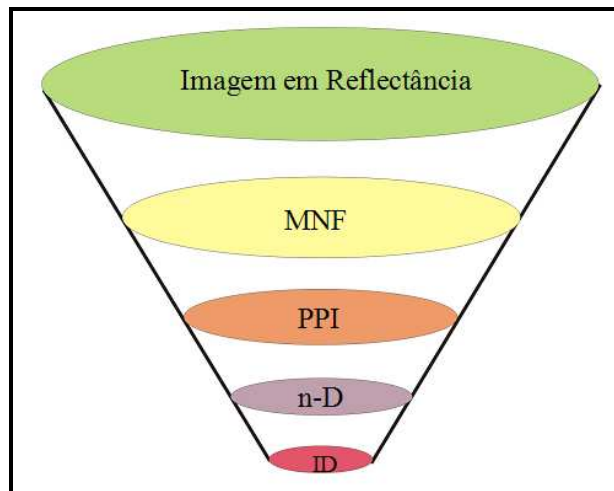


FIGURA 4.7 - Fluxograma do processamento implementado no ENVI para seleção inicial de pixels candidatos a membros de referência.

FONTE: Kruse et al. (1999).

4.4.1 - Transformação *Minimum Noise Fraction* (MNF) – Inversa

Para redução da alta correlação entre bandas (redundância de informação), inerente aos dados hiperespectrais, e segregação do ruído da imagem, aplicou-se a transformação MNF sobre os dados Hyperion.

Após o emprego da transformação linear MNF, realizou-se a separação da fração ruído do sinal através da inversão da transformação MNF, selecionando-se nesse caso as componentes de melhor qualidade visual das imagens (sem ruído aparente). Segundo Carvalho Júnior et al. (2002), como as imagens estão ordenadas de acordo com a qualidade, torna-se fácil realizar essa separação, considerando apenas as componentes relativas ao sinal, ou seja, desprezando as frações ruidosas. As imagens geradas com o processo de inversão apresentam espectros com pouco ruído.

4.4.2 - Índice de Pureza do Pixel (PPI)

A técnica PPI, que utiliza a abordagem de geometria convexa, foi aplicada com o objetivo de identificar os pixels espectralmente mais puros na imagem, candidatos a MRs. Esta técnica foi aplicada sobre o conjunto de bandas selecionadas no espaço MNF com os maiores autovalores. Um elevado número de iterações

(10.000) foi utilizado para gerar inúmeras projeções, com um valor limiar (*threshold*) de 3,5 números digitais (sendo que 1 número digital é igual a 1 desvio-padrão com relação à medida do pixel). Os pixels mais extremos em cada projeção foram pontuados como pixels puros.

4.4.3 - Visualização *n*-Dimensional

A ferramenta de visualização *n*-Dimensional foi utilizada para verificar a dispersão dos pixels indicados como “puros” pelo processo PPI, assim como a separabilidade entre as classes no espaço de atributos gerado pelas bandas MNF selecionadas. A inspeção se fez de forma interativa, selecionando-se as componentes com os maiores autovalores.

4.4.4 - Seleção dos Candidatos a MRs, Amostras de Validação e Obtenção da 1ª Biblioteca Espectral

Para seleção dos candidatos a MRs (Grupo 1) e das amostras de validação (Grupo 2), a imagem PPI foi sobreposta à imagem reflectância. Esta sobreposição permitiu também identificar os componentes de cena que seriam representados no modelo de mistura. Posteriormente, para cada grupo, os pixels apontados como “puros”, e que se localizavam em áreas onde foi realizada a identificação em campo, foram agrupados em regiões de interesse (ROIs) de acordo com a sua respectiva classe.

Os critérios adotados para a seleção dos pixels foram: (a) terem sido indicado pelo processo PPI; (b) estarem contidos em uma área homogênea; (c) serem de regiões distintas; e (d) ter sido verificado em campo a classe a qual pertence.

Através dos módulos *Create Spectral Library from ROIs* e *Create Metadata for Spectral Library* do *VIPER Tools*, os espectros de todos os pixels contidos nas ROIs do Grupo 1 foram extraídos, gerando a 1ª biblioteca espectral (.sli) e seu respectivo arquivo metadados (.csv).

No entanto, como o arquivo metadados original, criado pelo módulo *Create Metadata for Spectral Library* apresenta apenas as coordenadas (coluna; linha) de cada pixel, novas colunas com caracteres foram inseridas para informar as classes e subclasses dos materiais correspondentes a cada região de interesse (ROIs).

Por fim, através do módulo *Manage Spectral Libraries* todos os espectros contidos na primeira biblioteca espectral foram ordenados de acordo com suas respectivas classes, subclasses e valores de brilho, de forma a facilitar a identificação nas imagens *Square Arrays*.

4.5 – Seleção dos MRs e Geração da 2ª Biblioteca Espectral

4.5.1 - Geração das Imagens *Square Arrays* (RMSE, SAM, EM *Fraction*, *Shade Fraction* e *Constraint Code*)

Utilizando o módulo “*Create Square Arrays*” do *VIPER Tools*, as métricas de ajuste necessárias para o cálculo das métricas EAR, MASA e CoB foram computadas para todos os espectros da 1ª biblioteca espectral. Os parâmetros utilizados para o cálculo estão apresentados na Tabela 4.4.

Modo de restrição	Parcialmente restrito
Fração Mínima permitida	-6%
Fração Máxima permitida	1,06%
Máximo RMSE permitido	0,025

TABELA 4.4 - Parâmetros adotados no módulo “*Create Square Array*” (*VIPER Tools*) para o cálculo das métricas de ajuste.

4.5.2 – Avaliação das Métricas EAR, MASA e Cob

Antes de aplicar as métricas EAR, MASA e CoB para geração da 2ª biblioteca espectral, procurou-se neste estudo, avaliar individualmente o desempenho de cada métrica sobre os dados Hyperion. Para isso, cinco espectros de cada classe (que possui um MR) foram selecionados da 1ª biblioteca espectral. Os espectros com os melhores resultados (EAR, MASA e CoB) foram selecionados e agrupados separadamente, formando ao final três bibliotecas espectrais, uma para cada métrica. Posteriormente,

o modelo MESMA foi aplicado sobre um conjunto de 160 pixels “puros” (apontados pelo PPI), utilizando individualmente as bibliotecas geradas pelo EAR, MASA e CoB para comparação dos resultados.

4.5.3 – Geração da 2ª Biblioteca Espectral utilizando as Métricas EAR, MASA e CoB

A 1ª biblioteca espectral gerada pela aplicação sequencial dos métodos descritos no Item 4.4, passou por um processo de “refinamento”, através do emprego das métricas EAR, MASA e CoB, implementadas no Programa *VIPER Tools*. O objetivo foi obter um sub-conjunto de pixels com maiores probabilidades de constituírem MRs nos modelos de mistura SMA e MESMA.

Como mencionado no Item 2.5.3, o objetivo da aplicação das métricas é determinar qual espectro de uma classe é o mais representativo, e não propriamente o mais puro, ou seja, aquele que melhor modela a sua classe em uma biblioteca espectral. Para isso, é utilizado como parâmetro o RMSE (EAR) e o ângulo espectral (MASA) gerado entre o espectro de referência e o espectro modelado.

Roberts et al. (2007) utilizaram os três primeiros espectros, com os melhores resultados obtidos por cada métrica, para gerar a biblioteca espectral. Não há na literatura a indicação de um número ideal de espectros a serem selecionados. Portanto, cabe ao usuário a escolha e investigação para alcançar melhores resultados.

Para este estudo, foram selecionados três espectros para cada subclasse, ou seja, aqueles que apresentaram os melhores resultados para cada métrica, os menores valores para EAR e MASA e o maior índice CoBI.

4.6 – Modelos de Mistura

4.6.1 – Determinação do Modelo MESMA mais Adequado segundo os Critérios de Fração e RMSE

A avaliação do desempenho dos modelos MESMA com 2, 3 e 4 componentes foi realizada através do próprio aplicativo utilizando os MRs de cada classe contidos na 2ª biblioteca espectral. Os modelos foram aplicados sem restrição de fração e erro RMS, de forma a garantir que toda a amostra de pixels “puros” selecionados para a análise de desempenho fosse modelada. Por fim, os resultados obtidos foram comparados entre modelos MESMA para determinar qual o número ideal de MRs, em função do menor RMSE e da maior fração de pixels modelados.

Após a determinação do número ideal de MRs, o MESMA foi aplicado sobre a imagem Hyperion com os parâmetros de restrição indicados na Tabela 4.5.

Tipo de sombra	Fotométrica
Fração mínima permitida	-0,06
Fração máxima permitida	1,06
Fração máxima para sombra	0,8
Máximo erro RMS permitido	0,025
Máximo erro residual permitido	0,025
Número de bandas contíguas para o cálculo do erro residual	7

TABELA 4.5 - Parâmetros utilizados para aplicação do MESMA (Roberts et al., 1998; Dennison & Roberts, 2003).

4.6.2 - Geração das Imagens-fração e Imagem Classificada

As imagens fração foram geradas automaticamente pelo *VIPER Tools* para cada MR/classe (solo, vegetação ou água) utilizada pelo modelo. Nesse caso, a fração de cada MR não-sombra estará compreendida no intervalo de -6 a 106 % e para o MR sombra de 0 a 80 %. Para verificar a coerência das frações (abundâncias) calculadas, analisou-se uma composição colorida (RGB) com as imagens-fração vinculadas à imagem reflectância.

Para geração da imagem-fração de cada subclasse foi desenvolvida uma rotina em MatLab (APÊNDICE C). Sobre as imagens-fração geradas pelo VIPER *Tools*, a rotina identifica para cada pixel modelado qual classe (solo, vegetação ou água) possui maior fração. Posteriormente, identifica através do arquivo metadados, o espectro (subclasse) utilizado para modelar o pixel gerando, ao final, uma imagem com as suas proporções. Da mesma forma, é produzida uma imagem classificada, onde é atribuído ao pixel a subclasse com maior proporção (Figura 4.8).

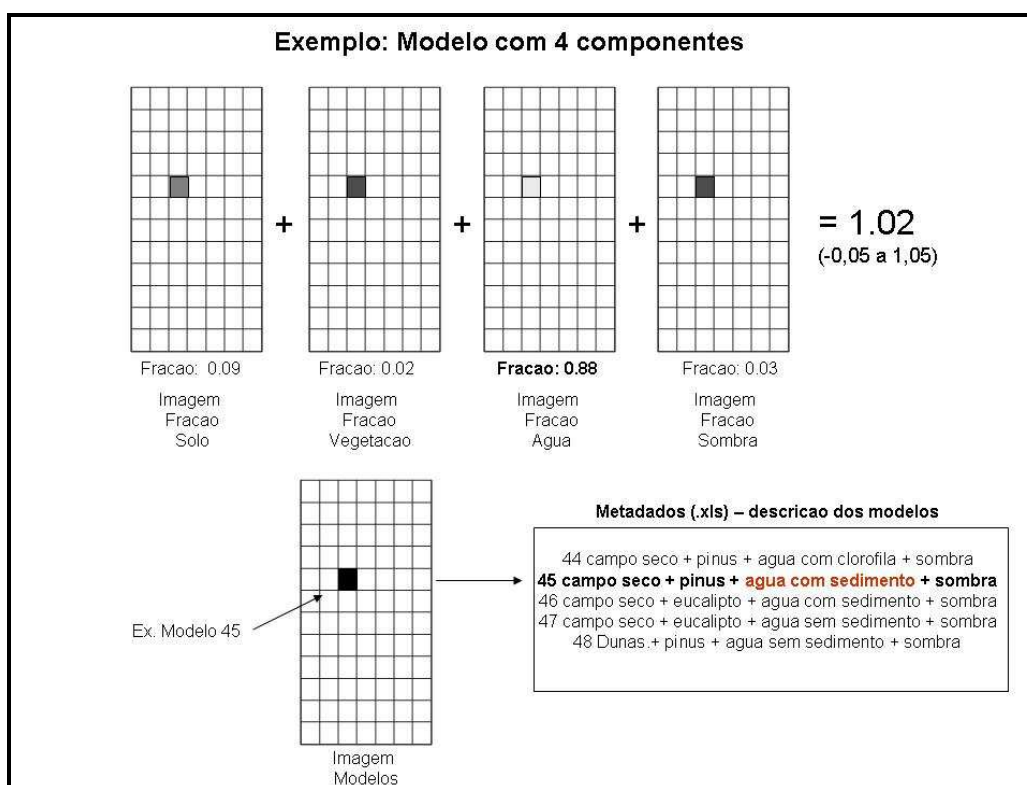


FIGURA 4.8 - Metodologia para geração das imagens-fração para cada subclasse e da imagem classificada, implementada no MatLab.

4.6.3 - Geração do Modelo SMA

Foram selecionados para o SMA, os MRs dos modelos MESMA que obtiveram os melhores resultados para modelar cada uma das subclasses, segundo os critérios: (a) menor RMSE; (b) número de pixels modelados; e (c) fração. Ao final, os modelos foram elencados para comparação dos resultados.

4.7 - Comparação dos Modelos e Avaliação da Acurácia

A comparação dos modelos SMA e MESMA (fração, RMSE e número de pixels modelados) foi realizada de forma individual para cada subclasse, devido ao fato do SMA permitir apenas um MR para cada componente de cena. Os modelos SMA e MESMA foram aplicados sobre a Amostra de Validação (Ver item 4.4) utilizando para ambos os mesmos parâmetros de restrição (Tabela 4.5).

Para verificação da acurácia dos modelos de mistura, alguns métodos baseiam-se na verificação em campo dos alvos imageados e na análise visual da proporção correspondente a cada um. Exemplos são os trabalhos de Rosso et al. (2005) e Dennison et al. (2003).

Rosso et al. (2005) distribuíram 100 polígonos, com dimensão de 20 x 20 m (para representar um pixel do AVIRIS) sobre uma imagem AVIRIS, representando as principais classes de cobertura da área de estudo. O percentual de cobertura de cada espécie foi avaliado visualmente em campo, para cada polígono, e sua localização foi identificada com o auxílio de fotografias aéreas. Após a execução dos modelos MESMA e SMA, os polígonos foram sobrepostos às imagens fração produzidas, para verificação da acurácia.

Dennison et al. (2003) distribuíram 74 polígonos (40 x 40 m) sobre uma imagem AVIRIS, com o auxílio de ortofotos (USGS) com 1 m de resolução para a avaliação da acurácia do modelo MESMA. A fração de cobertura foi baseada na análise visual do percentual de cobertura de cada uma das seis classes, identificadas em campo: 0-25%, 10-25%, 25-50%, 50-75%, 75-90%, e 90-100%.

Para o presente estudo, a determinação visual das frações para avaliação da acurácia dos modelos tornou-se inviável, pois os dados Hyperion adquiridos para este estudo foram originados no ano de 2004. Além disso, não há registros precisos (p. ex. mapas de cobertura, fotografias aéreas) para determinação da fração e tipo de cobertura existente da área de estudo. Dessa forma, não haveria como estimar em campo a proporção de elementos extremamente variáveis, como por exemplo, a

vegetação. Assim sendo, a avaliação da acurácia foi obtida em relação à desmistura dos pixels “puros” (amostra de validação), resultantes do processo PPI.

Teoricamente para um modelo desmisturar um pixel puro, de um determinado material, utilizaria uma fração próxima a 100% da sua classe correspondente no modelo, independente do número de MRs. Conseqüentemente, para os outros MRs, as frações tenderiam a 0%. Para exemplificar, se um modelo com três MRs (vegetação, solo e sombra) fosse utilizado para modelar um pixel puro de solo, o resultado esperado para as frações seriam respectivamente, 0 % de vegetação, 100 % de solo e 0 % de sombra (valores aproximados).

Dessa forma, as frações produzidas para cada material, por cada modelo, foram comparadas em relação ao RMSE produzido para avaliar o desempenho dos modelos de mistura SMA E MESMA.

CAPÍTULO 5

RESULTADOS E DISCUSSÃO

5.1 – Componentes de Cena

Os principais componentes de cena da área de estudo estão indicados na composição colorida verdadeira com as bandas do sensor Hyperion posicionadas em 638 nm (vermelho), 546 nm (verde) e 465 nm (azul) (Figura 5.1). Fotografias de campo de alguns desses componentes são mostradas na Figura 5.2.

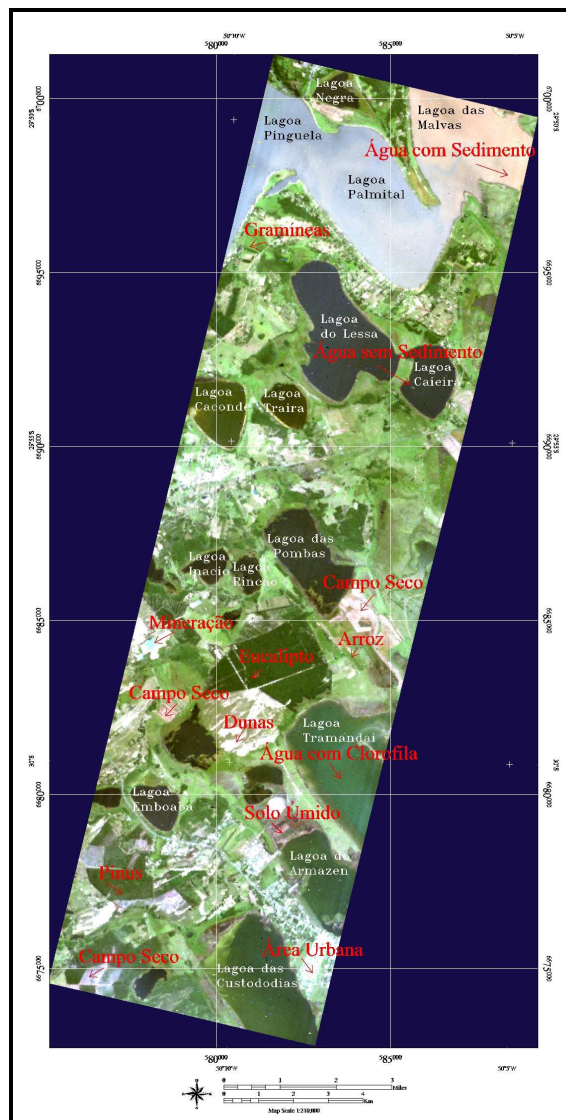


FIGURA 5.1 – Composição colorida verdadeira com as bandas posicionadas em 638 nm (vermelho), 546 nm (verde) e 465 nm (azul). Os principais componentes de cena estão indicados.



FIGURA 5.2 – Exemplos de componentes de cena identificados na área de estudo: (a) dunas; (b) gramíneas; (c) arroz; (d);e) campo seco; (f) eucalipto; e (g) pinus.

Na área de estudo, os corpos lagunares são os elementos que estão mais presentes, perfazendo uma área de aproximadamente 50% da imagem. Basicamente, identificam-se três diferentes tonalidades destas águas, que foram classificadas neste estudo como: água com sedimento, água sem sedimento e água com clorofila. Exemplos desses tipos de água são as Lagoas das Malvas, da Caieira e de Tramandaí, respectivamente (Figura 5.1).

O uso atual do solo é dominado pelo cultivo de arroz (Figura 5.2c) e pelo plantio de pinus (Figura 5.2g) e eucaliptos (Figura 5.2f) em pequenas e médias propriedades. Estes dois últimos estão presentes no centro sul da imagem, identificados pela coloração verde escuro para os eucaliptos e verde claro em tons intermediários para o arroz e pinus (Figura 5.1). Também se observam, na cena, duas áreas de extração de areia caracterizadas pelas lagoas de cor azul claro, presentes nas cavas da mineração.

A área de zonas de campo aberto é composta por vegetações rasteiras, principalmente gramíneas (Figura 5.2b), identificadas pelos tons de verde claro e situando-se entre os corpos lagunares espalhados em toda a imagem. Esta vegetação rasteira entremeada por arbustivas está igualmente presente nas dunas (Figura 5.2a), apresentando-se em tons de verde musgo salientado pela intensa cor branca, característica das areias quartzosas.

As zonas de campos secos caracterizam-se por uma vegetação seca dispersa, composta por galhos secos de pinus e palha de arroz, conforme visualiza-se nas Figuras 5.2d e 5.2e. Estes campos compõem a porção centro sul da imagem com uma tonalidade cinzenta e bege, respectivamente.

Outro elemento da cena é o solo úmido, identificado pela coloração marrom escuro, localizado ao lado da Lagoa Tramandaí.

Por último, pode-se destacar uma pequena porção da área urbana da cidade de Tramandaí e o reservatório petrolífero da Petrobrás situado entre as Lagoas das Custódias e do Armazém.

5.2 – Pré-processamento

Na Figura 5.3 pode-se observar o resultado obtido com o uso do módulo *Hyperion Tools* para a correção dos *stripes* na banda 11 do Hyperion para uma porção da área de estudo localizada na parte superior da cena. Como esperado, ocorreu uma significativa melhora em relação aos *stripes*. Para o efeito *smile*, que compreende pequenos deslocamentos no centro das bandas com o deslocamento do satélite, o algoritmo não produziu melhorias significativas (resultados não mostrados). Segundo Goodenough et al. (2003), para se obter bons resultados para correção do efeito *smile*, seria necessário atualizar os coeficientes de calibração do Hyperion, visto que provavelmente foram alterados após o seu lançamento em órbita. O efeito *smile*, por produzir deslocamentos da ordem de 2 a 3 nm do centro da banda, não tem impacto significativo na classificação ou detecção de materiais com técnicas hiperespectrais. De fato, a magnitude desses efeitos é inferior aos da variação na relação sinal-ruído do sensor do VNIR para o SWIR.




FIGURA 5.3 – Banda 11 (455 nm) do Hyperion (a) antes e (b) depois do *destriping* utilizando o módulo *Hyperion Tools*.

A correção atmosférica dos dados e sua conversão de valores de radiância para reflectância de superfície, utilizando o FLAASH e seguindo os procedimentos descritos no capítulo anterior, produziram espectros de reflectância consistentes com o esperado da literatura (Figura 5.4). O espectro da água apresentou baixa reflectância ($\rho < 0,2$) na faixa compreendida entre 0,45 e 0,7 μm , absorvendo toda a radiação eletromagnética fora desse intervalo. O espectro de solo mostrou valores crescentes

de reflectância com o aumento do comprimento de onda. O espectro da vegetação apresentou feições bem características de vegetação verde sadia, devido à intensa absorção da radiação nas regiões do azul e do vermelho e pela intensa reflexão na região do infravermelho próximo. Bandas de absorção de água das folhas também podem ser observadas em 980 nm e 1200 nm.




FIGURA 5.4 – Reflectância espectral de pixels de água, solo e vegetação verde após a correção atmosférica dos dados Hyperion. Os dados em torno de 1400 e 1900 nm não têm significado pela forte absorção atmosférica por vapor de água.

Para fins de correção geométrica, foram identificados e selecionados 16 pontos de controle (Tabela 5.1) sobre a imagem GeoCover, distribuídos ao longo de toda cena. Após o ajuste polinomial de segunda ordem e reamostragem pelo método de vizinho mais próximo, obteve-se como resultado uma precisão de 0,456702 pixels, o que equivale a aproximadamente 13,7 metros no terreno.

Pontos	Map X	Map Y	Image X	Image Y	Predict X	Predict Y	Error X	Error Y	RMS
Ponto 1	722.00	446.00	38.20	31.60	38.75	31.75	0.55	0.15	0.57
Ponto 2	923.00	975.00	187.20	248.40	186.57	248.15	-0.63	-0.25	0.67
Ponto 3	806.75	405.25	74.00	4.00	73.41	4.05	-0.59	0.05	0.59
Ponto 4	912.75	528.50	134.80	48.20	134.86	48.04	0.06	-0.16	0.17
Ponto 5	1155.50	507.50	242.60	12.60	242.46	12.64	-0.14	0.04	0.15
Ponto 6	1045.50	640.50	205.80	83.60	206.32	83.64	0.52	0.04	0.53
Ponto 7	629.75	1641.25	127.20	584.20	126.83	584.02	-0.37	-0.18	0.41
Ponto 8	556.00	1964.00	127.80	739.60	128.09	739.03	0.29	-0.57	0.64
Ponto 9	419.00	2064.00	77.00	799.00	76.94	799.18	-0.06	0.18	0.19
Ponto 10	269.00	2240.00	29.00	896.00	29.00	896.97	0.00	-0.03	0.03
Ponto 11	822.25	1397.50	187.00	451.00	187.22	451.55	0.22	0.55	0.59
Ponto 12	623.00	1951.50	157.33	725.67	157.15	726.14	-0.18	0.47	0.50
Ponto 13	502.00	1403.00	43.00	489.00	43.22	489.20	0.22	0.20	0.29
Ponto 14	666.00	1027.00	76.00	301.00	76.51	300.97	0.51	-0.03	0.51
Ponto 15	829.00	1751.00	229.00	612.00	229.08	611.76	0.08	-0.24	0.26
Ponto 16	554.50	933.50	16.00	271.00	15.53	270.79	-0.47	-0.21	0.51

TABELA 5.1 – Pontos de controle utilizados para o registro da imagem Hyperion. Valor RMS = 0,456702 obtido para o polinômio de 2ª ordem.

5.3 – Primeira Biblioteca Espectral e Amostras de Validação a partir dos Dados Hyperion

5.3.1 - Transformação Minimum Noise Fraction (MNF) – Inversa

O resultado obtido da transformação MNF (Tabela 5.2), aplicada às 143 bandas (VNIR e SWIR) do sensor Hyperion, apresentou os autovalores mais elevados nas 9 primeiras componentes MNF, responsáveis por 47,8 % da variância dos dados (Figura 5.5). As componentes seguintes apresentaram variância inferior a 1 %, sendo praticamente dominadas pela presença de ruído (Figura 5.6).

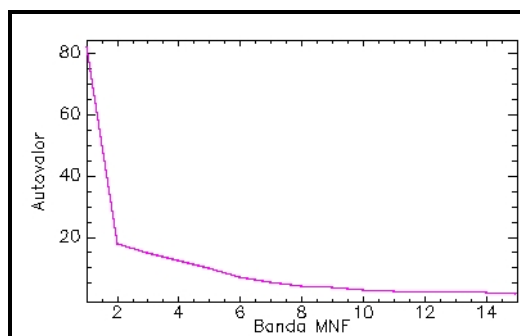


FIGURA 5.5 - Autovalores resultantes da aplicação da técnica MNF sobre as 143 bandas do VNIR e SWIR da imagem Hyperion.




FIGURA 5.6 - Transformação MNF aplicada sobre os valores de reflectância de superfície de 143 bandas do sensor Hyperion. No sentido da esquerda para direita, estão dispostas as seguintes componentes MNF: 1; 2; 3; 4; 5; 10 e 20.

MNF	Autovalor	%	% acumulativo
1	82.35851	24.63512	24.63512
2	18.19561	5.44268	30.07780
3	15.28461	4.57194	34.64974
4	12.89822	3.85812	38.50787
5	10.10912	3.02385	41.53171
6	7.13779	2.13506	43.66677
7	5.41892	1.62091	45.28768
8	4.42920	1.32486	46.61254
9	3.98156	1.19097	47.80351
10	3.02639	0.90526	48.70876
11	2.75463	0.82397	49.53273
12	2.63422	0.78795	50.32068
13	2.46309	0.73676	51.05744
14	2.27769	0.68130	51.73874
15	2.01034	0.60133	52.34008

TABELA 5.2 – Autovalores e percentual de variância correspondente às 15 primeiras bandas MNF.

Após a transformação MNF, realizou-se a transformação inversa sobre as 9 primeiras bandas MNF com o objetivo de diminuir o ruído dos dados. Na Figura 5.7 pode ser observado o resultado obtido sobre a curva de reflectância da vegetação, extraída de um pixel da imagem Hyperion, antes e depois da transformação MNF inversa.




FIGURA 5.7 – Curva espectral da vegetação antes e depois da transformação MNF inversa.

5.3.2 - Índice de Pureza do Pixel (PPI) e Visualizador

A técnica índice de pureza de pixel (PPI) foi aplicada sobre as 9 primeiras bandas MNF, que representaram a parte coerente da imagem (desprovida de ruído),

para detecção dos pixels candidatos a MRs. Foram realizadas 10.000 interações, com limiar de pureza de 3,5. Ao final, 14.101 pixels foram apontados como candidatos a MRs (Figura 5.8), representando 6,12 % da área imageada.




FIGURA 5.8 – Os pixels em vermelho (14.101 pixels) representam candidatos a MRs indicados pela técnica PPI sobre as 9 primeiras bandas MNF.

Esses pixels, identificados pela técnica PPI, ocorreram principalmente em porções da cena de 8 subclasses relacionadas com três classes principais (água, vegetação e solo): Água com Sedimento, Água sem Sedimento e Água com Clorofila (Água); Pinus, Eucalipto e Gramíneas (Vegetação); e Dunas e Campo Seco (Solo).

Sobre a imagem da Figura 5.8 e com o auxílio do visualizador *n*-Dimensional, foram selecionados manualmente um conjunto de pixels por subclasse para compor separadamente o Grupo 1 (candidatos a MRs) e o Grupo 2 (Amostra de Validação). Para o Grupo 1, foram selecionados 105 pixels, como regiões de interesse (ROIs), por subclasse, exceto para a subclasse Campo Seco, que obteve apenas 20 pixels indicados pelo processo PPI. Para compor a Amostra de Validação (Grupo 2), foram selecionados 80 pixels para cada subclasse. Para a subclasse Campo Seco foram selecionados os pixels vizinhos aos apontados pela técnica PPI, selecionados para o Grupo 1.

Classe	Subclasse	Número de pixels Grupo 1	Número de pixels Grupo 2
Água	Água com sedimento	105	80
	Água sem sedimento	105	80
	Água com clorofila	105	80
Vegetação	Pinus	105	80
	Eucaliptos	105	80
	Gramíneas	105	80
Solo	Dunas	105	80
	Campo Seco	20	80
Total de pixels para cada grupo		755	640

TABELA 5.3 - Classes, subclasses e número de pixels selecionados para compor o Grupo 1 (candidatos a MRs) e Grupo 2 (Amostra de Validação), resultante da aplicação seqüencial das técnicas MNF e PPI.

A Figura 5.9 ilustra a separabilidade das classes água, solo e vegetação, mostrando a dispersão dos pixels selecionados da aplicação seqüencial das técnicas MNF e PPI. A separabilidade das oito subclasses e dos pixels selecionados para compor a primeira biblioteca espectral (Grupo 1) está representada na Figura 5.10 e para a amostra de validação (Grupo 2) está representada na Figura 5.11. Os locais de

onde foram extraídos manualmente os pixels dessas oito subclasses estão indicados na Figura 5.12.

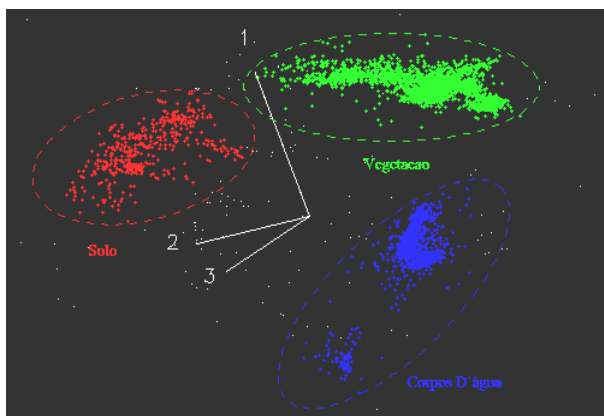


FIGURA 5. 9 – Projeção dos pixels candidatos a MRs, selecionados pela técnica PPI, no Visualizador n -Dimensional (espaço de atributos MNF 1, 2 e 3) para as três principais classes de cobertura (água, vegetação e solo).




FIGURA 5.10 - Projeção dos pixels selecionados para compor a primeira biblioteca espectral (Grupo 1) no Visualizador n -Dimensional (espaço de atributos MNF 1, 2 e 3) para as 8 subclasses de cobertura.




FIGURA 5.11 - Projeção dos pixels selecionados para compor a amostra de validação (Grupo 2) no Visualizador n -Dimensional (espaço de atributos MNF 1, 2 e 3) para as 8 subclasses de cobertura.

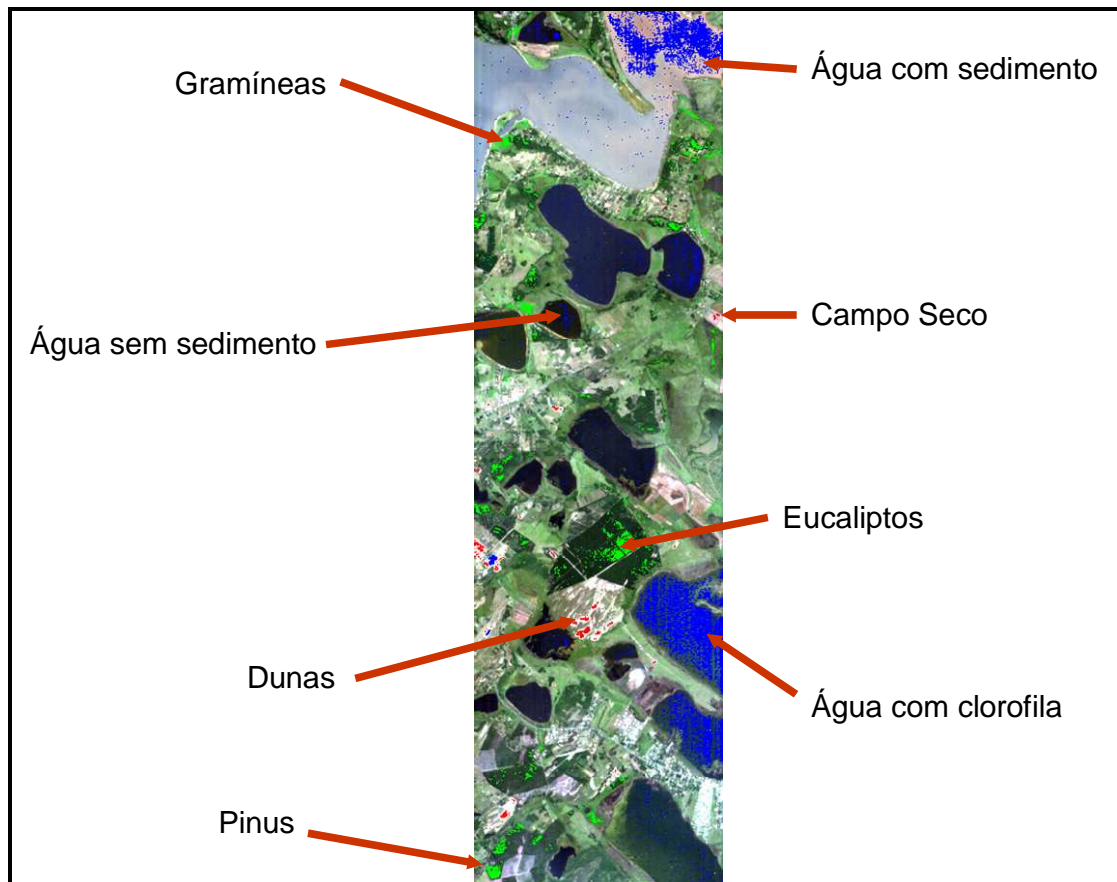


FIGURA 5.12 – Porções da cena Hyperion de onde foram extraídos os pixels selecionados da aplicação sequencial das técnicas MNF e PPI para compor o Grupo 1 (candidatos a MRs) e Grupo 2 (Amostra de Validação), envolvendo oito subclasses de cobertura. A composição colorida é verdadeira com as bandas posicionadas em 638 nm (vermelho), 546 nm (verde) e 465 nm (azul).

5.3.3 – Geração da 1ª Biblioteca Espectral através do VIPER Tools

Sobre a amostra de pixels do Grupo 1 (755 pixels candidatos a MRs na Tabela 5.3) foram aplicados sequencialmente os módulos *Create Spectral Library from ROIs*, *Create Metadata for Spectral Library* e *Manage Spectral Library* do VIPER Tools para gerar a primeira biblioteca espectral, criar o arquivo metadados e ordenar os espectros contidos na biblioteca de acordo com as suas respectivas classes, subclasses e valores de brilho. O arquivo com os metadados, contendo as informações espaciais de cada pixel (coordenadas “x” e “y”), foi editado através do Excel para inserir as classes e subclasses de cada um dos 755 espectros. Parte do arquivo metadados editado está mostrado na Figura 5.13.

	A	B	C	D
1	Name	Classe	Subclasse	Brilho
2	ACorpoDaguacomClorofila_X202_Y728	Água	Água com Clorofila	10.5051
3	ACorpoDaguacomClorofila_X203_Y728	Água	Água com Clorofila	12.8188
4	ACorpoDaguacomClorofila_X178_Y611	Água	Água com Clorofila	13.5556
5	ACorpoDaguacomClorofila_X181_Y613	Água	Água com Clorofila	13.6004
6	ACorpoDaguacomClorofila_X224_Y758	Água	Água com Clorofila	13.9257
7	ACorpoDaguacomClorofila_X202_Y722	Água	Água com Clorofila	15.9566
8	ACorpoDaguacomClorofila_X205_Y724	Água	Água com Clorofila	17.2166
9	ACorpoDaguacomClorofila_X180_Y614	Água	Água com Clorofila	18.1998
10	ACorpoDaguacomClorofila_X180_Y616	Água	Água com Clorofila	18.6913
11	ACorpoDaguacomClorofila_X203_Y722	Água	Água com Clorofila	19.3054
12	ACorpoDaguacomClorofila_X205_Y725	Água	Água com Clorofila	19.4656
13	ACorpoDaguacomClorofila_X204_Y724	Água	Água com Clorofila	2.26373
14	ACorpoDaguacomClorofila_X181_Y616	Água	Água com Clorofila	21.7486
15	ACorpoDaguacomClorofila_X176_Y616	Água	Água com Clorofila	23.0423

FIGURA 5.13 – Arquivo metadado .csv gerado pelo módulo *Create Metadata for Spectral Library* e posteriormente editado no Excel para inclusão das respectivas classes e subclasses.

5.4 - Geração da 2ª Biblioteca Espectral (VIPER Tools)

5.4.1 – Imagens *Square Array* (RMSE, SAM, EM Fraction, Shade Fraction e Constraint Code)

Para o cálculo das métricas de ajuste, foram computados todos os 755 espectros da 1ª biblioteca espectral, selecionados do uso sequencial das técnicas MNF, PPI e Visualizador *n*-Dimensional (Tabela 5.3), através do módulo “*Create Square Array*” do *VIPER Tools*. Os valores de erro (RMSE), ângulo espectral (SAM), fração do MR (EM Fraction), fração sombra (*Shade Fraction*) e os códigos de restrição (*Constraint Code*) foram calculados a partir da desmistura dos espectros das linhas (eixo x) pelos espectros das colunas (eixo y). Os resultados obtidos estão apresentados a seguir nas 5 imagens *Square Array* (755 colunas X 755 linhas) produzidas pelo módulo, onde os níveis de cinza estão associados aos valores produzidos por cada métrica de ajuste.

A Figura 5.14 ilustra as variações associadas ao erro médio quadrático (RMSE) no processo de modelagem entre espectros de classes e subclasses. Analisando visualmente a Figura 5.14, pode-se notar que os espectros da classe água

produziram os maiores valores de RMSE (pixels mais claros) ao modelarem os espectros da classe Solo e Vegetação. Isso ocorreu devido à diferença de brilho entre as classes (Figura 5.15). Em outras palavras, quando um espectro A, com maior brilho, modela um espectro B, com menor brilho, a fração estará compreendida entre 0 e 100%, e o RMSE será calculado como a diferença entre o espectro de maior brilho com o espectro de menor brilho. Quando a situação é inversa, a fração do espectro B será maior que 100% e o RMSE será calculado da diferença entre o espectro B com o brilho do espectro mais luminoso A. Assim, o RMSE será maior que o caso anterior. Os menores valores RMSE em cada classe (quando espectros da mesma classe são modelados entre si) foram obtidos pelos espectros com maior valor de brilho: Água com Sedimento (Corpos D'água), Dunas (Solo) e Gramíneas (Vegetação). Para a classe água, os espectros de Água com Clorofila e de Água sem Sedimento apresentaram baixo RMSE quando modelados entre si. O mesmo pode ser verificado para a Classe Vegetação, onde o Pinus e Eucalipto obtiveram baixo RMSE, o que poderá acarretar em erros de comissão.




FIGURA 5.14 – Imagem *Square Array* RMSE– erro RMS produzido pelo espectro da coluna “y” para modelar o espectro da linha “x”.




FIGURA 5.15 – Média dos valores de brilho, referente às 8 subclasses da 1ª biblioteca espectral.

As variações no ângulo SAM (radianos) para as classes e subclasses são mostradas na Figura 5.16. Como a técnica SAM considera apenas o ângulo gerado entre dois espectros, acaba sendo menos influenciada pela variação do brilho, resultando aparentemente em melhores resultados (maior distinção entre as classes). No entanto, assim como a métrica de ajuste RMSE, a SAM apresentou baixos valores angulares (radianos) quando espectros de Água com Clorofila e Água sem Sedimento, e espectros de Pinus e de Eucaliptos foram modelados entre si.




FIGURA 5.16 – Imagem *Square Array* - SAM – distância angular, medida em radianos, formada entre o espectro da coluna (eixo y) (espectro de referência) e o espectro da linha (eixo x).

A Figura 5.17 mostra que, assim como o RMSE, os valores de Fração MR utilizados para o espectro da coluna “x” modelar o espectro da linha “y” estão também relacionados com o seu valor de brilho. Os espectros que possuem maior brilho modelaram os espectros mais escuros produzindo frações inferiores a 106%. Por outro lado, os espectros de classes mais escuras modelaram os espectros de classes mais claras atingindo o valor máximo de fração (106%) (p.ex., espectros de Água com Clorofila modelando espectros de Dunas). Como os espectros da coluna “x” modelaram os espectros da linha “y” utilizando também a componente sombra, e estando os valores de fração dos espectros não-sombra compreendidos entre -6% e 106%, as frações produzidas de sombra resultaram da diferença da fração utilizada pelo espectro não-sombra da coluna (espectros de referência) menos 1,06.




FIGURA 5.17 – Imagem *Square Array* - Fração MR e Fração Sombra – corresponde à fração SMA utilizada pelo espectro da coluna (eixo y) para modelar o espectro da linha (eixo x). Os valores para fração sombra são calculados pela subtração da fração do espectro menos um.

Na imagem *Constraint Code* (Figura 5.18), os espectros da Classe Água não modelaram outras classes. No entanto, os espectros de Água com Clorofila e Água sem Sedimento foram modelados por todos os outros espectros de outras classes da biblioteca espectral, sem restrição alguma (Código “0”). A exceção foram os espectros de Água com Clorofila que foram modelados pelos espectros de Água sem Sedimento com restrição parcial (Código “1” - fração superior a 106%, mas com RMSE abaixo de 0,025). Os espectros de Água com Sedimento, Campo Seco, Dunas e Gramíneas foram modelados unicamente pelos seus espectros (espectros especialistas). Na Classe Vegetação, a quase totalidade dos espectros de Pinus

modelou os espectros de Eucalipto sem restrição alguma (Código “0”). Os espectros de Gramíneas modelaram alguns espectros de Pinus com restrição parcial, assim como alguns espectros de Eucalipto. Os espectros da Classe Solo não modelaram espectros da Classe Vegetação, ocorrendo o mesmo no sentido inverso.

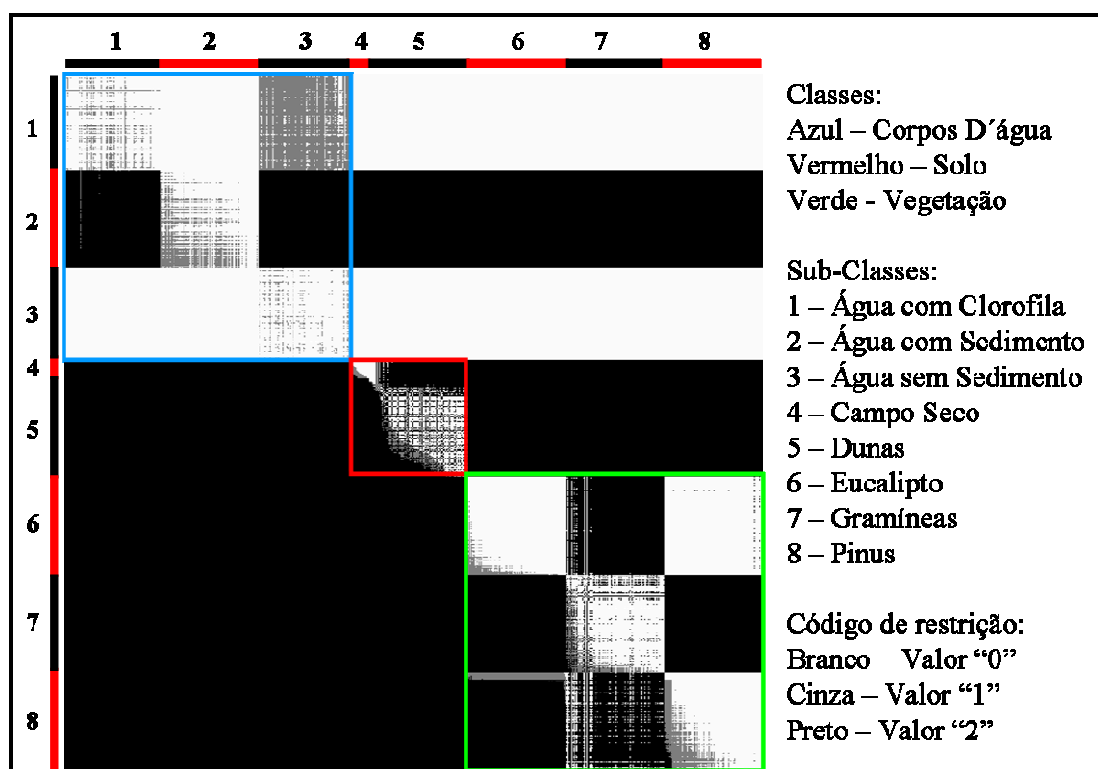


FIGURA 5.18 – Imagem *Constraint Code* – “1” indica se o modelo foi parcialmente restrito (as frações modeladas excederam o limite, mas não excederam o RMSE estipulado); “2” se o RMSE foi excedido (completamente restrito); e “0” (zero) para modelos sem qualquer restrição.

Da análise das Figuras 5.14 a 5.18, pôde-se concluir que devido à semelhança do comportamento espectral entre materiais da mesma classe, haverá uma possível confusão quando esses espectros estiverem associados a uma mesma componente do modelo de mistura. Isto pôde ser claramente observado entre as subclasses Água com Clorofila e Água com Sedimento e entre Pinus e Eucalipto. Dessa forma, a análise das imagens *Square Array* permite ao usuário prever onde, provavelmente, ocorrerão erros de comissão.

5.4.2 – Avaliação das métricas EAR, MASA e CoB

Antes de selecionar os MRs para compor a segunda biblioteca espectral utilizando as métricas EAR, MASA e CoB, é interessante analisar o desempenho de cada métrica na separação de classes utilizando uma amostra teste. Os resultados são mostrados na Figura 5.19. A média RMSE refere-se ao erro produzido pelo modelo MESMA ao modelar um conjunto de 160 pixels (20 para cada sub-classe) selecionados aleatoriamente. Para tal análise ou cálculo de erro do modelo, o MESMA foi aplicado em três etapas utilizando os espectros com menores valores de EAR, MASA e CoB, respectivamente.




FIGURA 5.19 – Valores de RMSE resultantes do uso do MESMA utilizando separadamente os MRs selecionados pelas métricas EAR, MASA e CoB e uma amostra-teste aleatória de 160 pixels.

Analisando o gráfico da Figura 5.19 e o da Figura 5.20, que mostra a variação dos valores de RMSE por pixel, dentro de cada subclasse, verificou-se que o desempenho das métricas é dependente da subclasse analisada. Embora a métrica CoB tenha obtido resultados ligeiramente melhores (exceto para as subclasses Gramíneas (MASA) e Água com Clorofila (EAR), as diferenças no desempenho de EAR, MASA e CoB não foram significativamente expressivas. Dessa forma, dada a dependência do desempenho da métrica por subclasse, optou-se pelo uso conjunto das três métricas nas etapas subsequentes do trabalho, visando a escolha dos MRs para o

refinamento da primeira biblioteca espectral e para conseqüente geração da segunda biblioteca espectral, que será discutida no próximo tópico.

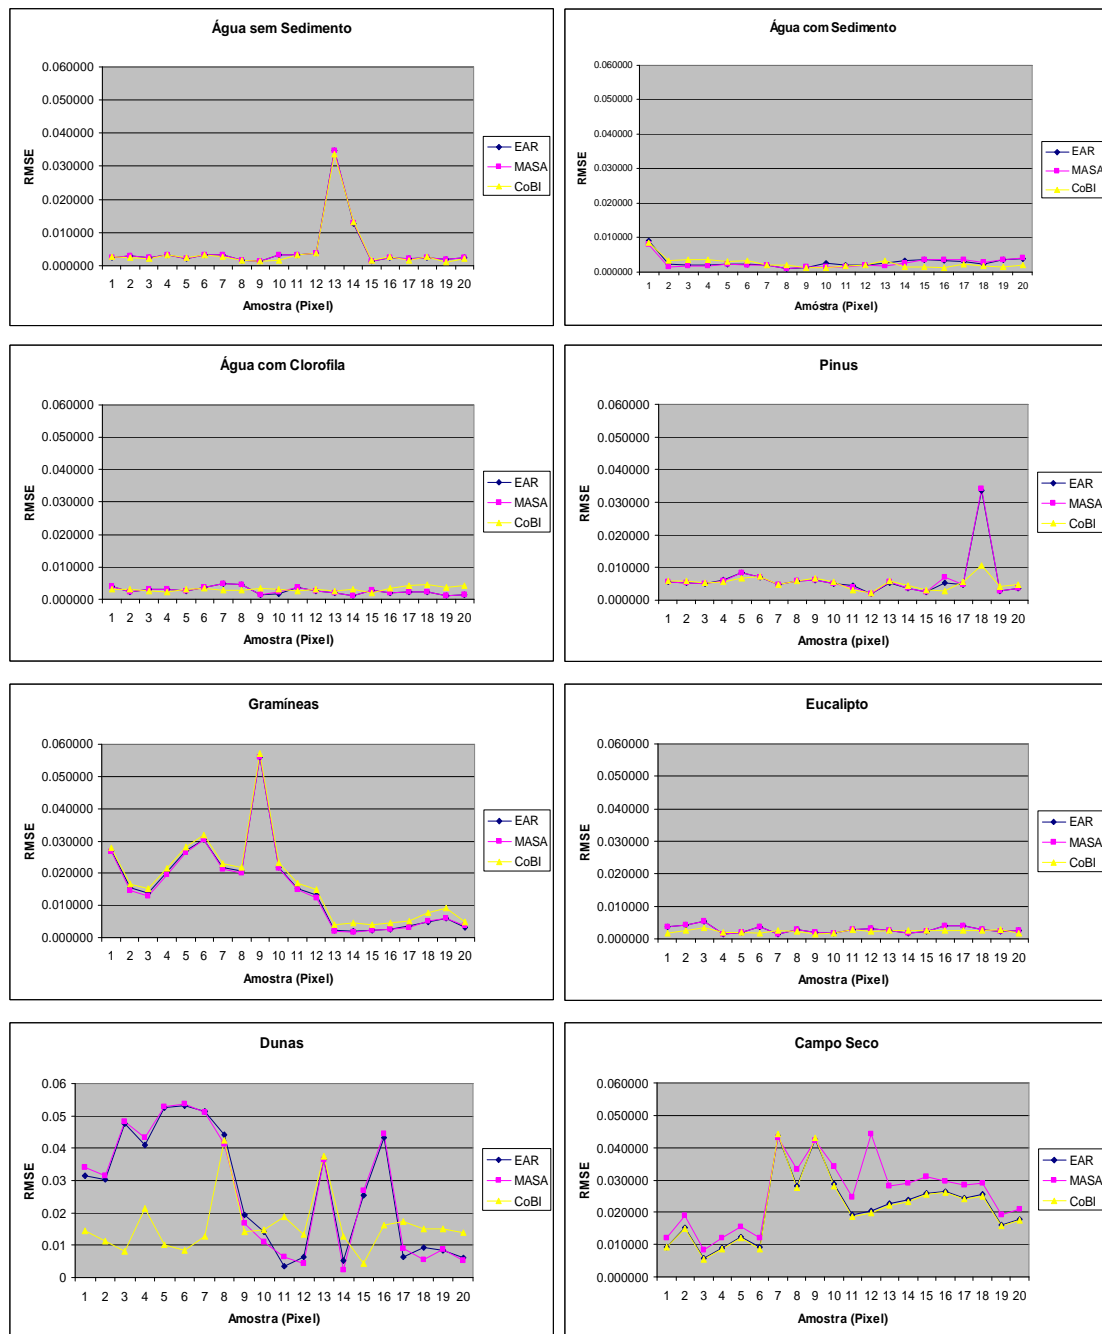


FIGURA 5.20 – Variação dos valores de RMSE em cada subclasse (20 pixels) resultante da aplicação do modelo MESMA utilizando separadamente os MRs selecionados pelas métricas EAR, MASA e CoB.

5.4.3 – Seleção dos MRs através das Métricas (EAR, MASA e CoB) para Geração da 2ª Biblioteca Espectral

O uso combinado das métricas EAR, MASA e CoBI, calculadas pelo módulo “Calculate EAR/MASA/CoB (EMC)” do VIPER *Tools*, resultou na seleção de 23 espectros representativos das oito subclasses mencionadas (Tabela 5.4). Para a subclasse Dunas, os espectros foram selecionados apenas pelas métricas EAR e MASA, pois o índice CoBI apresentou um valor muito baixo ou discrepante.

No	Espectro (MR)	Classe	Subclasse	Brilho	EAR	MASA	In CoB	Out CoB	CoBI
1	CampoSeco_X252_Y313	Solo	Campo Seco	2301.96	0.004189	0.01828	0	0	0
2	CampoSeco_X250_Y313	Solo	Campo Seco	2209.08	0.005129	0.018854	0	0	0
3	CampoSeco_X253_Y314	Solo	Campo Seco	2437.13	0.005789	0.026221	19	201	0.004726
4	Dunas_X117_Y639	Solo	Dunas	4735.91	0.02091	0.049839	0	0	0
5	Dunas_X112_Y646	Solo	Dunas	4369.08	0.023756	0.048694	0	0	0
6	Eucalipto_X161_Y556	Vegetação	Eucalipto	1194.2	0.002973	0.017533	0	0	0
7	Eucalipto_X163_Y555	Vegetação	Eucalipto	1181.35	0.003024	0.017624	0	0	0
8	Eucalipto_X158_Y551	Vegetação	Eucalipto	1245.76	0.004856	0.028736	104	201	0.004928
9	Gramíneas_X52_Y305	Vegetação	Gramíneas	2388.07	0.010109	0.034415	0	0	0
10	Gramíneas_X52_Y307	Vegetação	Gramíneas	2412.86	0.010208	0.034936	0	0	0
11	Gramíneas_X58_Y308	Vegetação	Gramíneas	2520.4	0.010714	0.036702	102	207	0.004693
12	Pinus_X21_Y888	Vegetação	Pinus	1651.06	0.00507	0.023631	104	306	0.003237
13	Pinus_X18_Y893	Vegetação	Pinus	1575.48	0.005328	0.0241	0	0	0
14	Pinus_X25_Y889	Vegetação	Pinus	1669.65	0.005253	0.024516	104	306	0.003237
15	Água com Clorofila_X180_Y615	Água	Água com Clorofila	44.1982	0.00254	0.231465	0	0	0
16	Água com Clorofila_X207_Y722	Água	Água com Clorofila	46.2025	0.002558	0.233612	0	0	0
17	Água com Clorofila_X225_Y756	Água	Água com Clorofila	66.4347	0.004374	0.41362	102	98	0.010105
18	Água com Sedimento_X144_Y15	Água	Água com Sedimento	186.978	0.003029	0.075188	0	0	0
19	Água com Sedimento_X209_Y25	Água	Água com Sedimento	168.724	0.003369	0.077079	0	0	0
20	Água com Sedimento_X142_Y13	Água	Água com Sedimento	318.737	0.01568	0.412722	104	201	0.004928
21	Água sem Sedimento_X171_Y253	Água	Água sem Sedimento	26.1767	0.002487	0.333666	0	0	0
22	Água sem Sedimento_X203_Y239	Água	Água sem Sedimento	22.0614	0.002498	0.334485	0	0	0
23	Água sem Sedimento_X171_Y258	Água	Água sem Sedimento	27.1614	0.002727	0.369349	97	1	0.989796

TABELA 5.4 – Pixels selecionados (23 candidatos a MRs), com base nas métricas EAR, MASA e CoB (EMC), para compor a segunda biblioteca espectral.

Como pode ser verificado na tabela acima, os espectros que apresentaram o menor EAR, apresentaram também o menor MASA. Para estes casos foram escolhidos os espectros com segundo menor valor MASA.

Espectros de reflectância de pixels da imagem Hyperion indicados na Tabela 5.4 são mostrados na Figura 5.21. Os espectros para representar a Classe Água apresentaram comportamentos bem distintos. Os espectros da subclasse Água com Sedimento apresentaram picos de reflectância ($\rho = 11,3\%$) na faixa do vermelho (618 nm), típico de água com elevada concentração de material inorgânico em suspensão. A Água com Clorofila obteve os maiores valores de reflectância ($\rho = 3,74\%$) na região do verde (567 nm), sendo por esse motivo, forte indicador da presença de material orgânico em suspensão. A Água sem Sedimento, apresentou os menores valores de reflectância, aproximadamente 1,88%, para toda a região do visível, indicando ausência de matéria em suspensão.

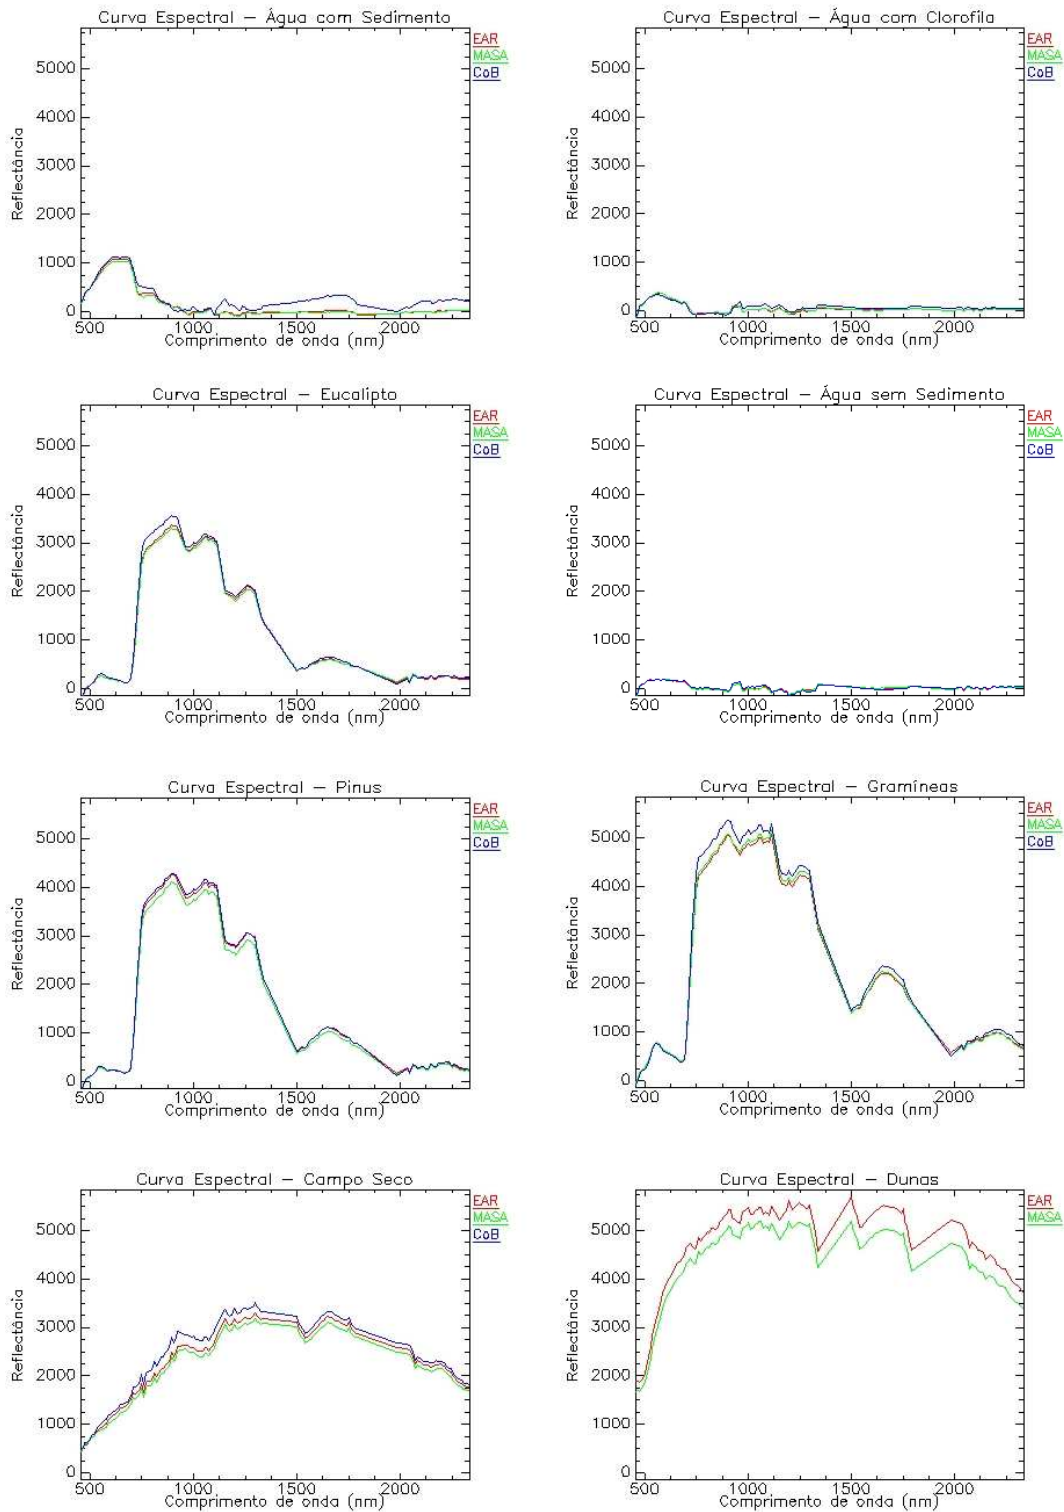


FIGURA 5.21 – Espectros de reflectância ($\times 10^4$) dos MRs selecionados a partir do uso das métricas EAR, MASA e CoB para gerar a segunda biblioteca espectral. Os dados em torno de 1400 e 1900 nm não têm significado pela forte absorção atmosférica por vapor d’água.

Os espectros selecionados para representarem as três subclasses de vegetação apresentaram curvas espectrais típicas da vegetação verde sadia, caracterizada pela

alta absorção da radiação eletromagnética nas regiões do azul e do vermelho e alta reflectância na região do infravermelho próximo, além das feições de absorção nos comprimentos de onda 0,98 e 1,2 μm causados pela presença de água foliar. Os valores de reflectância das espécies pinus e eucaliptos apresentaram diferenças pequenas no infravermelho próximo, entre 41 % e 36 %⁵ respectivamente, e uma curva espectral muito semelhante. Alguns espectros dessas espécies que não foram selecionados, mas que pertenciam à primeira biblioteca espectral, possuíam valores intermediários de reflectância para ambas as espécies. Os espectros de gramíneas alcançaram, nesse mesmo comprimento de onda, 51% de reflectância. Os espectros da Classe Solo também apresentaram comportamentos bem característicos, com valores crescentes de reflectância relacionados ao aumento do comprimento de onda. Os espectros de dunas, compostas por areia quartzosa, apresentaram alta reflectância em todos os comprimentos de onda, característica principal do mineral quartzo. Já os espectros de campo seco apresentaram menor reflectância, com pico ($\rho = 33\%$) em 1295 nm.

5.5 – Modelos de Mistura MESMA e SMA

5.5.1 – Determinação do Modelo MESMA mais Adequado segundo os Critérios de Fração e RMSE

O resultado do desempenho dos modelos de 2, 3 e 4 componentes ou MRs (Tabela 5.5), gerados a partir da 2ª biblioteca espectral, pode ser observado na Tabela 5.6. Embora as subclasses Água com Sedimento, Gramíneas e Eucalipto tenham sido modeladas com valores aproximados a 100% para os modelos com 2 e 3 componentes, os modelos com 4 componentes obtiveram os menores RMSE e maior fração para as cinco subclasses restantes.

Nº de componentes	1ª componente	2ª componente	3ª componente	4ª componente	Nº modelos
2	Água / Vegetação / Solo	Sombra			23
3	Água / Solo	Vegetação	Sombra		126
4	Solo	Vegetação	Água	Sombra	405

TABELA 5.5 – Número de modelos MESMA gerados a partir da 2ª biblioteca espectral para avaliação do desempenho.

⁵ Valores de reflectância obtidos no comprimento de onda 893 nm.

Modelo MESMA	2 componentes		3 componentes		4 componentes	
	Fração	RMSE	Fração	RMSE	Fração	RMSE
Água com Sedimento	1.02217	0.00223	1.02841	0.00181	1.03081	0.00149
Água sem Sedimento	0.91303	0.00266	0.89781	0.00216	0.93011	0.00186
Água com Clorofila	0.88428	0.00220	0.88503	0.00182	0.89634	0.00144
Campo Seco	0.90515	0.01973	0.79719	0.00477	0.80143	0.00415
Dunas	0.95379	0.01555	0.93474	0.01387	0.96329	0.00493
Pinus	0.91926	0.00526	0.92953	0.00357	0.93104	0.00327
Eucalipto	0.99622	0.00285	0.99648	0.00219	0.99593	0.00191
Gramíneas	0.99479	0.00808	0.97786	0.00450	0.97538	0.00329
Média	0.94859	0.00732	0.93088	0.00434	0.94054	0.00279

TABELA 5.6 – Resultado obtido pelos modelos MESMA de 2, 3 e 4 componentes (MRs) sobre a amostra de validação. Valores representados em azul indicam o menor RMSE e valores representados em vermelho as frações que mais se aproximaram a 100%.

5.5.2 - Modelos MESMA

Os modelos MESMA com quatro componentes foram gerados atribuindo-se à 1ª componente os espectros da classe Solo (Dunas e Campo Seco), à 2ª componente os espectros da classe Vegetação (Pinus, Eucalipto e Gramíneas) e à 3ª componente os espectros da classe Água (Água com Sedimento, sem Sedimento e com Clorofila). Para as restrições de fração máxima e mínima permitida para o MR, fração máxima de sombra e RMSE, solicitados pelo módulo “Run SMA/MESMA” do *VIPER Tools*, foram utilizados os parâmetros descritos na metodologia (Tabela 4.5).

Com os critérios estabelecidos, aproximadamente 85% da imagem Hyperion foi modelada pelo MESMA, o que corresponde a 195.725 pixels (total de 230.400 pixels). A maioria dos pixels das subclasses Água, Campo Seco, Pinus, Gramíneas e Eucalipto foi modelada e corretamente classificada. A subclasse Dunas teve apenas 46,25 % da sua amostra modelada (Tabela 5.7).

Subclasse	% modelado
Água com Sedimento	100.00%
Água sem Sedimento	100.00%
Água com Clorofila	100.00%
Campo Seco	100.00%
Dunas	46.25%
Pinus	100.00%
Eucalipto	100.00%
Gramíneas	97.50%

TABELA 5.7 – Resultado obtido pelo modelo MESMA com 4 componentes sobre a amostra de validação.

Nas imagens-fração da Figura 5.22 percebe-se que as classes Solo e Vegetação, mais a componente sombra, foram empregadas em conjunto para modelar as suas respectivas áreas, com exceção dos locais que apresentaram cobertura homogênea de Pinus, Eucalipto, Gramíneas, Dunas e Campo Seco (verificado pelo alto valor de brilho nas imagens fração Solo e Vegetação). Os pixels que correspondiam à classe Água (Água com Clorofila, Água com Sedimento e Água sem Sedimento) foram, em sua maioria, modelados por seus respectivos MRs mais sombra, chegando em alguns casos, a serem modelados com aproximadamente 70% de sombra (Figura 5.23).




FIGURA 5.22 – Imagens fração geradas pelo VIPER *Tools* para cada componente do modelo MESMA: (a) imagem fração Solo, (b) imagem fração Vegetação, (c) imagem fração Água e (d) imagem fração Sombra.



FIGURA 5.23 – Imagem fração Sombra de porção da cena, indicando pixels da classe Água com Sedimento modelados com alta fração de sombra (aproximadamente 70%).

A Imagem RMSE (Figura 5.24a) indicou que os maiores erros foram produzidos pelo MESMA ao modelar pixels de Gramíneas e Dunas, devido a alta variabilidade espectral desses alvos. A representação espacial das variações das frações solo, vegetação e água é mostrada na Figura 5.24b. Pode-se observar que as porções mais destacadas da imagem (com maior brilho) correspondem às áreas com maior abundância de um tipo de cobertura, como aquelas destinadas ao cultivo de pinus, eucalipto e arroz. O mesmo pode ser verificado para os corpos d'água e campos secos. As áreas cobertas por outros materiais (p.ex. gramíneas) apresentaram sinais de maior mistura espectral.




FIGURA 5.24 – a) Imagem RMSE; e (b) composição colorida fração Solo (vermelho), fração vegetação (verde) e fração água (azul). As áreas em preto em (b) não foram modeladas.

A Figura 5.25 mostra o intervalo de fração produzido pelo MESMA para as oito subclasses representadas neste estudo. Com o auxílio dos histogramas de cada imagem pôde-se verificar que a maior parte dos pixels da Classe Corpos D'água foram modelados com frações superiores a 90 %. Na Classe Vegetação, as médias de frações produzidas variaram entre 60 % (Gramíneas) e 90 % (pinus e eucalipto). A Classe Solo apresentou os menores valores de fração, com aproximadamente 50% para subclasse Campo Seco. A subclasse Dunas obteve uma distribuição praticamente linear com intervalo entre 20 % e 104 %.




FIGURA 5.25 – Imagens Fração das 8 subclasses: (a) Água com Clorofila; (b) Água com Sedimento; (c) Água sem Sedimento; (d) Campo Seco; (e) Dunas; (f) Eucalipto; (g) Gramíneas; e (h) Pinus.

A classificação final (Figura 5.26), obtida a partir das imagens fração solo, vegetação e água, mostra a distribuição espacial das oito subclasses representadas

neste estudo. Pode-se verificar que, como previsto na análise das imagens *Square Array*, algumas áreas que correspondiam ao cultivo de eucaliptos foram classificadas como pinus, não havendo confusão para o caso inverso. Para a classificação da água, o resultado parece ser consistente em relação à imagem colorida verdadeira da Figura 5.1. Entretanto, nos locais menos profundos (margens), ocorreu uma pequena confusão entre as subclasses Água com Sedimento e Água com Clorofila, devido principalmente ao efeito de fundo. Assim como ocorreu com as amostras de validação, as áreas cobertas por dunas deixaram, em sua imensa maioria, de ser modeladas. A área urbana, que não foi representada nos modelos de mistura, foi modelada em parte como campo seco (solo). A Figura 5.27 mostra o resultado obtido pelo MESMA ao modelar parte da área urbana do Município de Tramandaí, localizada no canto inferior direito da imagem Hyperion.




FIGURA 5.26 – Resultado obtido pelo modelo MESMA com 4 componentes. Imagem classificada a partir da componente com maior fração.




FIGURA 5.27 – Resultado obtido pelo MESMA sobre parte da área urbana do Município de Tramandaí: (a) Imagem classificada. As áreas em tom avermelhado foram classificadas como campo seco (solo); (b) imagem QuickBird sobre a área urbana.

5.5.3 - Modelos SMA

Os modelos SMA selecionados a partir dos modelos MESMA, utilizados com maior frequência e que apresentaram o menor RMSE para modelar as amostras de cada subclasse, estão apresentados na Tabela 5.8.

Sub-classes	Amostra (80 pixels)			MESMA - 4 componentes			
	Modelo	Fração	RMSE	MF Solo	MF Vegetação	MF Corpo D'água	Sombra
Água com Sedimento	283	1.02759	0.00148	Dunas_X117_Y639	Gramíneas_X52_Y307	Água com Sedimento_X144_Y15	Sombra
Água sem Sedimento	107	0.94644	0.00185	Campo Seco_X250_Y313	Eucalipto_X158_Y551	Água sem Sedimento_X203_Y235	Sombra
Água com Clorofila	362	0.86719	0.00206	Dunas_X112_Y646	Gramíneas_X52_Y307	Água com Clorofila_X207_Y722	Sombra
Campo Seco	122	0.77347	0.00480	Campo Seco_X250_Y313	Gramíneas_X52_Y307	Água com Sedimento_X209_Y25	Sombra
Dunas	292	0.77443	0.00566	Dunas_X117_Y639	Gramíneas_X58_Y308	Água com Sedimento_X144_Y15	Sombra
Pinus	315	0.90687	0.00354	Dunas_X117_Y639	Pinus_X18_Y893	Água sem Sedimento_X171_Y258	Sombra
Eucalipto	96	1.02352	0.00169	Campo Seco_X250_Y313	Eucalipto_X163_Y555	Água com Sedimento_X142_Y13	Sombra
Gramíneas	129	0.92743	0.00860	Campo Seco_X250_Y313	Gramíneas_X58_Y308	Água com Clorofila_X225_Y756	Sombra

TABELA 5.8 – Modelos SMA selecionados a partir dos modelos MESMA de melhor desempenho.

Pôde-se observar que devido ao SMA considerar todos os pixels como mistura de um único conjunto inicial de MRs, os pixels “puros” selecionados para a avaliação dos modelos pertencentes às subclasses que não estavam representadas por um MR no modelo deixaram de ser modelados ou foram modelados com altos valores de

sombra e RMSE. Além disso, apenas uma pequena porção da cena Hyperion foi modelada quando os diferentes modelos SMA da Tabela 5.8 foram gerados. Como exemplo, conforme indicado na última linha da Tabela 5.9, o modelo SMA 107 modelou apenas 13,92% dos pixels da cena Hyperion, enquanto o modelo 129 modelou 55,21% dos pixels.

Percentual de pixels modelados pelos modelos SMA									
Subclasse	Pixels	Modelo SMA							
		362	283	107	315	96	129	292	122
Água com Sedimento	640	0.00%	96.25%	0.00%	0.00%	0.00%	0.00%	96.25%	76.25%
Água sem Sedimento		98.75%	0.00%	92.50%	100.00%	0.00%	98.75%	0.00%	0.00%
Água com Clorofila		100.00%	23.75%	3.75%	35.00%	23.75%	100.00%	22.50%	73.75%
Campo Seco		0.00%	0.00%	86.25%	0.00%	100.00%	98.75%	0.00%	100.00%
Dunas		18.75%	43.75%	0.00%	28.75%	0.00%	0.00%	43.75%	0.00%
Pinus		0.00%	0.00%	0.00%	100.00%	0.00%	0.00%	0.00%	0.00%
Eucalipto		0.00%	0.00%	62.50%	96.25%	95.00%	0.00%	0.00%	0.00%
Gramíneas		18.75%	42.50%	0.00%	0.00%	0.00%	86.25%	47.50%	43.75%
Imagem		230400	28.57%	31.85%	13.92%	17.68%	26.25%	55.21%	31.80%

TABELA 5.9 – Percentual de pixels modelados sobre a amostra de validação e imagem pelos oito modelos SMA da Tabela 5.7. As células marcadas em cinza correspondem às subclasses representadas por MRs em cada modelo.

Exemplos de imagens SMA, classificadas com base no MR de maior fração em cada pixel, são apresentados para os modelos 107 (13,92% de pixels classificados) e 129 (55,21% de pixels classificados) nas Figuras 5.28a e 5.28b, respectivamente. Conforme pode ser observado nestas figuras, foram classificadas na imagem as porções correspondentes às subclasses que estavam representadas no modelo de mistura. Como na maior parte da cena há ocorrência de gramíneas, os modelos que continham esta subclasse para componente vegetação, modelaram maior porcentagem, como o caso do modelo 129, composto por MRs das subclasses campo seco (solo), gramíneas (vegetação) e água com clorofila (água). O modelo SMA 107, que possui na sua formulação um MR para subclasse eucalipto, não conseguiu modelar toda a área correspondente a essa subclasse.

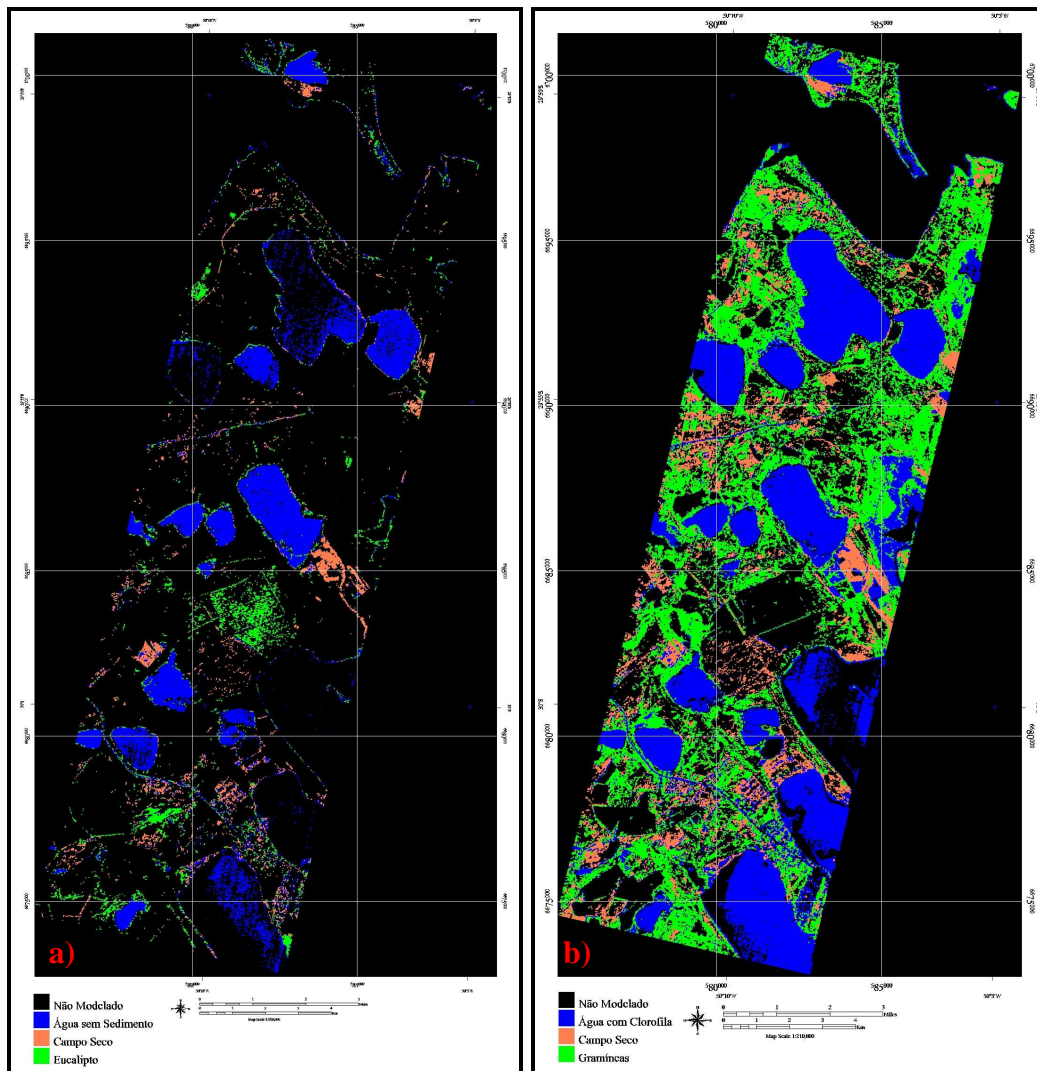


FIGURA 5.28 – Classificações SMA com base no MR de maior fração no pixel para os modelos (a) 107 com 13,92 % da imagem classificada e (b) 129 com 55,21% da imagem classificada.

5.6 - Análise comparativa dos resultados obtidos pelos modelos MESMA e SMA quanto ao critério de fração e RMSE

A Tabela 5.10 mostra, de forma comparativa, o desempenho do modelo MESMA em relação aos diferentes modelos SMA da Tabela 5.8 ao modelar os 640 pixels “puros” da amostra de validação. Como pode ser observado na Tabela 5.10, o MESMA apresentou menores valores médios de RMSE e maiores valores médios de fração quando comparado com os demais modelos SMA. Algumas subclasses também não foram modeladas pela abordagem SMA, pois cada classe foi representada por apenas um MR. Em grande parte, foram modelados na imagem

somente os pixels constituídos por materiais que estavam representados no modelo SMA. Apesar de não ter sido avaliado nesse estudo o uso de espectros generalistas, para o caso da abordagem SMA, a utilização desses espectros teria produzido melhores resultados, no que se refere a número de pixels modelados.

Diferentemente do SMA, o MESMA permitiu detectar a diversidade de materiais pertencentes a uma mesma classe como, por exemplo, a de vegetação, utilizando um conjunto de 18 espectros. Os erros de classificação (erros de comissão) detectados entre subclasses, não foram causados pela limitação do modelo MESMA, mas sim pela semelhança do comportamento espectral entre alguns materiais, como por exemplo, entre as subclasses pinus e eucalipto.

Cabe também ressaltar que para a aplicação do MESMA não há a necessidade, *a priori*, de selecionar o espectro mais representativo ou mais puro para modelar um determinado material, como foi verificado na abordagem SMA. O próprio MESMA pode ser utilizado como ferramenta de seleção desses MRs. Através da análise dos resultados, o usuário poderá selecionar os espectros que modelaram com menor RMSE para formar o conjunto final de MRs que será utilizado pelo modelo.

As áreas não modeladas na imagem pelo MESMA indicam que alguns componentes de cena ou foram mal representados - os MRs selecionados não representaram toda a variabilidade espectral do material - ou deixaram de ser representados - não foram apontados pelo processo PPI - produzindo maiores erros.

Subclasse	Modelo MESMA		Modelos SMA															
			362		283		107		315		96		129		292		122	
	Fração	RMSE	Fração	RMSE	Fração	RMSE	Fração	RMSE	Fração	RMSE	Fração	RMSE	Fração	RMSE	Fração	RMSE	Fração	RMSE
Água com Sedimento	1.02365	0.00155	NM	NM	1.00375	0.00175	NM	NM	NM	NM	NM	NM	NM	NM	1.00368	0.00174	1.03290	0.00159
Água sem Sedimento	0.92864	0.00188	0.56120	0.00355	NM	NM	0.91758	0.00194	0.84506	0.00255	NM	NM	0.58183	0.00416	NM	NM	NM	NM
Água com Clorofila	0.89634	0.00144	0.90756	0.00168	0.22405	0.00539	0.99587	0.00310	0.98355	0.00365	0.23318	0.00589	0.91383	0.00329	0.22386	0.00533	0.22546	0.00542
Campo Seco	0.80144	0.00415	NM	NM	NM	NM	0.88352	0.00701	NM	NM	0.87366	0.00651	0.80291	0.00500	NM	NM	0.81276	0.00480
Dunas	0.87751	0.00419	0.93115	0.00539	0.84818	0.00436	NM	NM	0.89045	0.00507	NM	NM	NM	NM	0.84795	0.00427	NM	NM
Pinus	0.91886	0.00331	NM	NM	NM	NM	NM	NM	0.91918	0.00353	NM	NM	NM	NM	NM	NM	NM	NM
Eucalipto	0.99736	0.00197	NM	NM	NM	NM	0.96480	0.00289	0.82512	0.00941	1.02026	0.00241	NM	NM	NM	NM	NM	NM
Gramíneas	0.96161	0.00567	0.97749	0.00587	0.98430	0.00506	NM	NM	NM	NM	NM	NM	0.93616	0.00678	0.94310	0.00529	0.98174	0.00396
Médias	0.92568	0.00302	0.84435	0.00412	0.76507	0.00414	0.94044	0.00374	0.89267	0.00484	0.70904	0.00494	0.80868	0.00481	0.75465	0.00416	0.76321	0.00394

TABELA 5.10 – Valores de RMSE e de fração resultantes dos modelos MESMA e SMA aplicados na modelagem do conjunto de pixels da amostra de validação. “NM” indica as subclasses não modeladas. Os valores em negrito indicam a fração obtida pelo modelo SMA (derivado do MESMA) que obteve o melhor resultado ao modelar a subclasse correspondente.

Uma comparação do desempenho dos modelos MESMA e SMA para classificar adequadamente os principais componentes de cena pode ser vista também nas Figuras 5.29a (SMA; modelo 129) e 5.29b (MESMA). A capacidade do modelo SMA em distinguir um maior número de componentes de cena é seriamente comprometida em razão do modelo utilizar um conjunto “fixo” de MRs para cada componente, principalmente na distinção entre variedades de uma mesma classe. Além disso, o RMSE aumentou consideravelmente quando pixels constituídos por outros materiais que não aqueles presentes no modelos, foram modelados, diminuindo o número total de pixels modelados (modelo 129; 55,21 %). No entanto, as frações produzidas para aqueles materiais que estavam representados nos modelos foram similares às produzidas pelo MESMA. Já o MESMA foi capaz de identificar, na primeira aplicação, a maior parte dos constituintes de cena e suas respectivas variações, além de modelar uma grande porção da imagem (85 %).

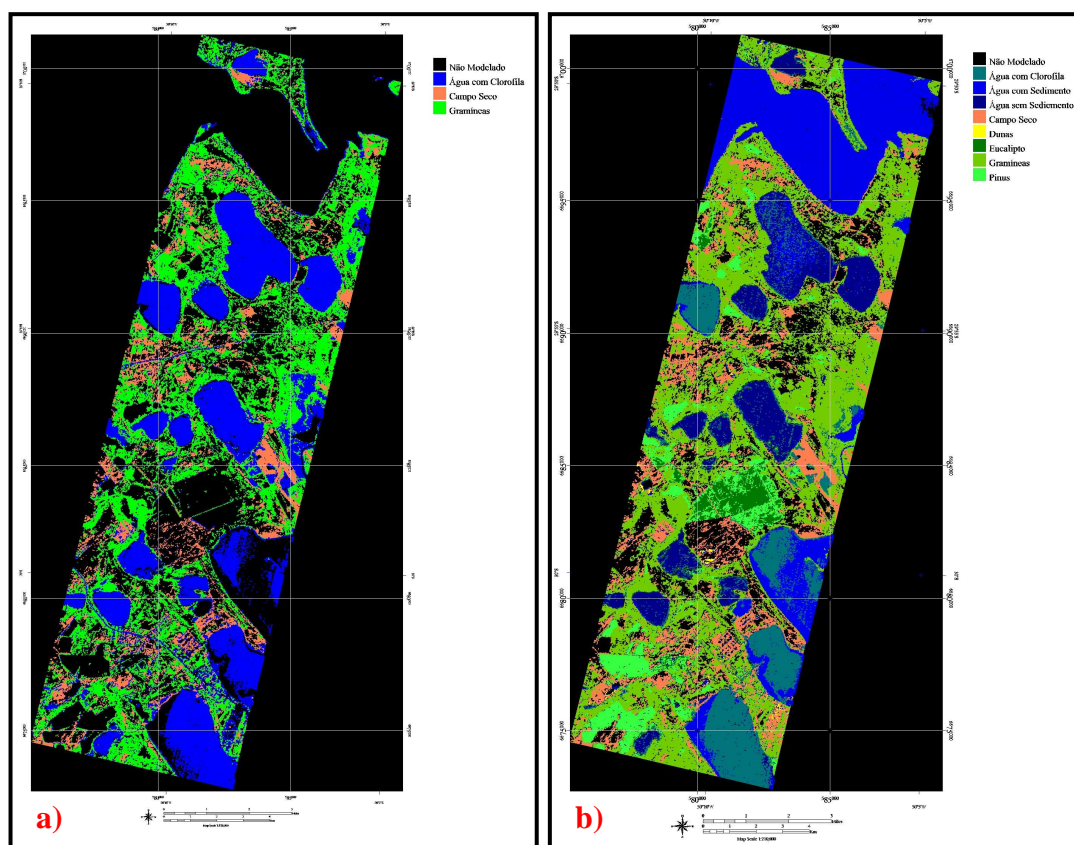


FIGURA 5.29 – Comparação entre as classificações resultantes da fração dominante do MR para os modelos (a) SMA 129 e (b) MESMA.

CAPÍTULO 6

CONCLUSÕES E SUGESTÕES

As principais conclusões relacionadas com os objetivos específicos definidos na Introdução são apresentadas abaixo.

Em relação à avaliação das técnicas de processamento digital, aplicadas aos dados Hyperion para seleção de MRs, pôde-se concluir que:

- a) Os processamentos *Minimum Noise Fraction* (MNF), *Pixel Purity Index* (PPI) e Visualizador *n*-Dimensional podem ser usados como um ponto de partida para identificação de um grupo de pixels candidatos a MRs;
- b) A seleção final dos MRs para composição dos modelos SMA e MESMA pode ser feita com o uso das métricas EAR, MASA e CoB implementadas no VIPER Tools, que, se usadas em conjunto, são menos sensíveis aos efeitos da baixa relação sinal-ruído do sensor Hyperion.

Em relação à comparação do desempenho dos modelos SMA e MESMA para classificação dos principais componentes de cena, pôde-se concluir que:

- a) Quando aplicado sobre a imagem e sobre a amostra de validação, o modelo MESMA de 4 componentes (Solo = dunas e campo Seco; vegetação verde = pinus, eucalipto e gramíneas; água = com Sedimentos em suspensão, sem Sedimentos e com clorofila; sombra) descreveu adequadamente a diversidade dos componentes de cena, incluindo materiais dentro de uma mesma classe (p.ex. pinus e eucalipto). O MESMA produziu menores valores de RMSE e uma maior quantidade de pixels modelados na cena (85% contra 55%) do que o SMA. De fato, a capacidade do modelo SMA em distinguir um maior número de componentes de cena foi afetada em razão de o modelo utilizar um conjunto “fixo” de MRs para cada componente e pixel;

- b) A aplicação do modelo MESMA sobre os dados Hyperion permitiu identificar e quantificar satisfatoriamente os materiais constituintes da área de estudo, havendo apenas uma pequena confusão intra-classe, onde MRs da subclasse Pinus modelaram alguns pixels de Eucalipto. As frações produzidas pelos modelos MESMA ao modelarem pixels “puros” corresponderam aos valores esperados, atingindo na sua maioria, frações superiores a 90 % com baixo RMSE;
- c) Como o número de componentes do modelo é limitado pelo Programa *VIPER Tools* e o modelo SMA não permite a variação dos MRs, pixels de materiais distintos dos materiais representados pelo modelo foram modelados, resultando em erros de comissão. Além disso, o modelo SMA não foi capaz de representar a variabilidade espectral de um mesmo material. Alguns pixels que possuíam materiais representados pelo modelo deixaram de ser modelados, resultando em erros de omissão.
- d) Os materiais distintos aos utilizados pelo modelo SMA, quando modelados, apresentaram altos valores de erro RMS e valores negativos para componente sombra.

Em relação à utilização do Programa *VIPER Tools* para execução dos modelos MESMA, SMA e seleção dos MRs, pôde-se concluir que:

- a) O Programa *VIPER Tools* mostrou-se uma ferramenta bastante eficaz para seleção dos MRs mais representativos de cada subclasse e para aplicação dos modelos de mistura SMA (*Spectral Mixture Analysis*) e MESMA (*Multiple Endmember Spectral Mixture Analysis*), possuindo uma interface simples e amigável;
- b) Para os modelos de mistura, os produtos gerados pelo *VIPER Tools* restringem-se às imagens-fração, RMSE e Modelo, não havendo a possibilidade de gerar uma imagem classificada;

- c) Ao modelo MESMA é permitido variar apenas o tipo de MR e não o número de componentes, aumentando assim o erro RMS ao modelar pixels constituídos por um único material – para o caso de modelos com três e quatro componentes serem aplicados. No entanto, entende-se que esta variação aumentaria consideravelmente o tempo computacional para os processamentos;
- d) O número de componentes que poderá ser aplicado aos modelos de mistura MESMA e SMA, incluindo a componente sombra, é limitado a quatro, visto que somente é possível a inclusão de no máximo três bibliotecas espectrais no módulo “*Run SMA/MESMA*” do *VIPER Tools*, não havendo assim, a possibilidade de testar modelos com maior número de componentes;
- e) Para o caso de MRs derivados da própria imagem é fundamental um conhecimento *a priori* das classes que serão representadas, pois cabe ao usuário atribuí-las aos espectros no arquivo metadados, gerado automaticamente pelo *VIPER Tools*;
- f) As métricas EAR, MASA e CoB foram implementadas para auxiliar na identificação dos MRs mais representativos, ou seja, aqueles que melhor modelam a sua própria classe. No entanto, para uma análise quantitativa precisa das frações produzidas, faz-se necessário a aplicação de MRs “puros”;
- g) A métrica CoB não considera o ângulo espectral formado entre o espectro de referência e o espectro modelado. O módulo “*Create Square Array*” - que calcula as métricas de ajuste, necessárias para os cálculos das métricas EAR, MASA e CoB - permite ao usuário restringir apenas os valores de fração máxima e mínima da componente não-sombra, de fração máxima da componente sombra e o máximo erro RMS.

Os resultados, como um todo, demonstram o potencial da aplicação dos modelos MESMA com dados hiperespectrais do sensor Hyperion/EO-1, mesmo considerando a baixa relação sinal/ruído do instrumento, especialmente no SWIR. Recomenda-se em estudos futuros:

- a) Investigar a influência da variação dos parâmetros de entrada (fração máxima e mínima dos componentes não-sombra, fração máxima de sombra, máximo erro RMS e erro residual), solicitados pelo programa *VIPER Tools*, no desempenho dos modelos de mistura;

- b) Realizar um controle de campo concomitante com a aquisição dos dados de imagem para análise dos resultados. Combinações de diferentes estágios evolutivos da vegetação, e sua relação com as frações produzidas pelos modelos de mistura, podem, dessa forma, ser devidamente avaliados;

- c) Obter espectros de campo ou laboratório de modo a possibilitar uma comparação com os espectros obtidos da imagem e avaliar seus desempenhos com os modelos de mistura;

- d) Avaliar o uso de espectros especialistas e generalistas e sua relação com as frações produzidas pelos modelos de mistura.

REFERÊNCIAS BIBLIOGRÁFICAS

- Adams J.B. & Adams J. Geologic mapping using Landsat MSS and TM images: Removing vegetation by modeling spectral mixtures. *In: Thematic Conf. Remote Sens. for Expl. Geol. ERIM, 3, Proceedings, v. 2, p. 615-622, 1984.*
- Adams, J. B. & Smith, M. O. Spectral Mixture Modeling: A New Analysis of Rock and Soil Types at the Viking Lander 1 Site. **Journal of Geophysical Research**, v. 91, n. B8, p. 8098-8112, 10 julho 1986.
- Adams, J. B.; Smith, M. O.; Gillespie, A. R. Imaging spectroscopy: Interpretation based on spectral mixture analysis. In C. M. Pieters, & P. A. J. Englert (Eds.), *Remote geochemical analysis: Elemental and mineralogical composition* (pp. 145– 166). Cambridge, England: Press Syndicate of University of Cambridge. 1993.
- Adler-Golden, S. M.; Matthew, M. W.; Bernstein, L. S.; Levine, R. Y.; Berk, A.; Richtsmeier, S. C.; Acharya, P. K.; Anderson, G. P.; Felde, G.; Gardner, J.; Hike, M.; Jeong, L. S.; Pukall, B.; Mello, J.; Ratkowski, A.; Burke, H. Atmospheric correction for shortwave spectral imagery based on MODTRAN4. **SPIE Proc. Imaging Spectrometry**, n. 3753, p. 61-69, 1999.
- Barry, P. **EO-1/Hyperion Science Data User's Guide**. Redondo Beach, CA: TRW Space, Defense & Inform. Syst., 2001. Disponível em: <http://eo1.gsfc.nasa.gov/new/general/Disk2/HyperionScienceDataUsersGuide_public_L1B.pdf> Acesso em: 12 ago. 2006.
- Barry, P.; Segal, C.; Pearlman, J.; Jarecke, P.; Folkman, M.; Nelson, N.; Yokoyama, K.; Shepanski, J.; Casement, S.; Carman, S. Hyperion Data Collection: Performance Assessment and Science Application. 2001. Disponível em: <http://eo1.gsfc.nasa.gov/new/validationReport/Technology/TRW_EO1%20Papers_Presentations/09.pdf> Acesso em: 21 set. 2006.
- Bateson, A. & Curtiss, B. A method for manual endmember selection and spectral unmixing, **Remote Sensing of Environment**, v. 55, p. 229-243, 1996.
- Bateson, C.A.; Asner, G.P.; Wessman, C. Endmember Bundles: A new approach to incorporating endmember variability into spectral mixture analysis. **IEEE Transactions on Geoscience and Remote Sensing**, v. 38, p. 1083-1094, 2000.
- Boardman, J. W. & Kruse, F. A. Automated spectral analysis: a geological example using AVIRIS data, north Grapevine Mountains. Nevada: in *Proceedings, ERIM Tenth Thematic Conference on Geologic Remote Sensing*, Environmental Research Institute of Michigan, Ann Arbor, MI, p. I-407-418, 1994.
- Boardman, J.W.; Kruse, F.A.; Green, R.O. Mapping target signatures via partial unmixing of AVIRIS data in Summaries of the 5th JPL Airborne Earth Science Workshop, JPL Publication 95-1, Jet Propulsion Laboratory, Pasadena, CA. v. 1, p. 23-26, 1995.

- Borel, C.G. & Gerstl, S.A.W. Nonlinear spectral mixing models for vegetative and soil surfaces. **Remote Sensing of Environment**, v. 47, p. 403-16, 1994.
- Borel, C. C. & Schlapfer, D. Atmospheric pre-corrected differential absorption techniques to retrieve columnar water vapor: Theory and Simulations: in Summaries of the 6th Annual JPL Airborne Earth Science Workshop, JPL Pub. 96-4, Vol. 1. AVIRIS Workshop, Jet Propulsion Laboratory, California Institute of Technology, Pasadena, Calif., p. 13-22, 1996.
- Brasil. Ministério da Agricultura. Instituto Nacional de Colonização e reforma Agrária – INCRA. **Levantamento e Avaliação de Recursos Naturais, Sócio-Econômicos e Institucionais do Rio Grande do Sul**. Brasília, v.2, 1973.
- Carrere, V. & Conel, J. Recovery of atmospheric water vapor total column abundance from imaging spectrometer data around 940 nm - Sensitivity analysis and application to Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) data. *Remote Sensing of Environment*, v. 44, n. 2-3, p. 179-204, 1993.
- Carvalho, A. P. F.; Guimarães, R. F.; Carvalho Junior, O. A.; Bustamante, M. M. C. Metodologia para Análise de Mistura Espectral em Imagens TM-Landsat. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2001, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2001. p. 1531-1538.
- Carvalho Júnior, O. A.; Carvalho, A. P. F., Meneses, P. R., Guimarães, R. F. Classificação e eliminação dos ruídos em imagens hiperespectrais pela análise sequencial da transformação por fração de ruído mínima. **Revista Brasileira de Geofísica**, v. 20, n. 1, p. 31-41, 2002.
- Carvalho Júnior, O. A.; Latorre, M.; Dias, L. A. V.; Carvalho, A. P. F.; Guimarães, R. F.; Meneses, P. R. Comparação dos métodos GREEN e ATREM para correção atmosférica de imagens hiperespectrais AVIRIS. **Espaço & Geografia**, v. 5, n. 1, p. 179-197, 2002.
- Carvalho Júnior, O. A.; Carvalho, A. P. F., Meneses, P. R., Guimarães, R. F. , Martins, E. S. Análise de imagens hiperespectrais pelo método Multiple Endmember Spectral Mixture Analysis (MESMA) em depósito supergênico de níquel. **Revista Brasileira de Geociências**, v.33, n. 1, p. 63-74. 2003.
- Chabrillat, S. *Imaging Spectrometry: Geoscience Applications*. GeoForschungsZentrum Potsdam (GFZ), 2007. CD-ROM
- Clark, R. N.; Swayze, G. A.; Rowan, L. C.; Livo, K.E.; Watson, K. Mapping surficial geology, vegetation communities, and environmental materials in our national parks: The USGS imaging spectroscopy integrated geology, ecosystems, and environmental mapping project: in Summaries of the 6th Annual JPL Airborne Earth Science Workshop, JPL Pub. 96-4, Vol. 1. AVIRIS Workshop, Jet Propulsion Laboratory, California Institute of Technology, Pasadena, Calif., p. 55-56, 1996.

- Clark, R.N.; Boardman, J.; Mustard, J.; Kruse, F.; Ong, C.; Pieters, C.; Swayze, G. Mineral Mapping and Applications of Imaging Spectroscopy: *in* Proceedings, IGARSS 2006, 31 July – 4 August, Denver, Colorado.
- Condit, H. R. The spectral Reflectance of American Soils. **Photogrammetric Engineering**, v. 36, n. 9, p. 955-966, 1970.
- Crósta, A. P. **Processamento Digital de Imagens de Sensoriamento Remoto**. 1. ed. Campinas: UNICAMP Ed., 1992. 164 p.
- Datt, B.; McVicar, T. R.; Niel, T. G. V.; Jupp, D. L. B.; Pearlman, J. S. Preprocessing EO-1 Hyperion Hyperspectral Data to Support the Application of Agricultural Indexes. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 6, p. 1246-1259, 2003.
- Dennison, P. E. & Roberts, D. A. Endmember selection for multiple endmember spectral mixture analysis using endmember average RMSE. **Remote Sensing of Environment**, v. 87, n. 2-3, p. 123-135, 2003a.
- Dennison, P. E. & Roberts, D. A. The effects of vegetation phenology on endmember selection and species mapping in southern Califórnia chaparral. **Remote Sensing of Environment**, v. 87, n. 2-3, p. 295-309, 2003b.
- Dennison, P. E.; Halligan, K. Q.; Roberts, D. A. A comparison of error metrics and constraints for multiple endmember spectral mixture analysis and spectral angle mapper. **Remote Sensing of Environment**, v. 93, n. 3, p. 359-367, 2004.
- Dennison, P. E.; Roberts, D. A. Wildfire temperature and land cover modeling using hyperspectral data. **Remote Sensing of Environment**, v. 100, n. 2, p. 212-222, 2006.
- Ducart, D. F. **Caracterização da alteração hidrotermal associada às ocorrências auríferas de Los Menucos, Argentina, por meio de técnicas de sensoriamento remoto e espectroscopia de reflectância** Campinas: UNICAMP, 2004. 97 p. Dissertação (Mestrado) – Programa de Pós-Graduação em Geociências, Universidade de Campinas, Campinas, 2004.
- Ducart, D. F.; Crosta, A. P.; Souza Filho, C. R. Processamento de imagens hiperespectrais do EO-1/Hyperion para o mapeamento de alteração hidrotermal na Patagônia Argentina. In: Simpósio Brasileiro de Sensoriamento Remoto, 13, 2007, Florianópolis **Anais....** São José dos Campos: INPE, 2007, p. 6449-6451.
- Dyk, A.; Goodenough, A. S.; Bhogal, A. S.; Pearlman, J.; Love, J. Geometric Correction and Validation of Hyperion and ALI Data for EVEOSD. **IEEE Transactions on Geoscience and Remote Sensing**, v. 1, p. 579-583, 2002. Disponível em: <http://rseng.cs.uvic.ca/DaveIEEEpub/IGARSS02_4.pdf> Acesso em: 11 set. 2006.
- ENVI User's Guide - versão 3.4**. Research Systems, Set. 2000.

- EO-1 User's Guide.** Disponível em: <<http://eo1.usgs.gov/userGuide/index.php?page=program>>. Acesso em: 11 ago. 2006.
- Folkman, M.; Pearlman, J.; Liao, L.; Jarecke, P. **EO-1/Hyperion hyperspectral imager design, development, characterization, and calibration.** 2000. Disponível em: <http://eo1.gsfc.nasa.gov/new/validationReport/Technology/TRW_EO1%20Papers_Presentations/07.pdf>. Acesso em: 26 nov. 2006.
- Fuckner, M. A. **Aplicação de imagens ASTER no estudo do ambiente urbano de São Paulo e Rio de Janeiro.** São José dos Campos: INPE, 2008. 235 p. Dissertação (Mestrado) – Programa de Pós-Graduação em Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2008.
- Galvão, L. S.; Formaggio, A. R.; Tisot, D. A. Discrimination of sugarcane varieties in Southeastern Brazil with EO-1 Hyperion data. **Remote Sensing of Environment**, v. 94, n. 4, p. 523-534, 2005.
- Gao, B. & Goetz, A. F. H. Column atmospheric water vapor and vegetation liquid water retrievals from airborne imaging spectrometer data. **Journal of Geophysical Research**, v. 95, n. D4, p. 3549-3564, 1990.
- Gao, B.-C. & Goetz, A. F. H. Column atmospheric water vapor and vegetation liquid water retrievals from airborne imaging spectrometer data. **J. Geophys. Res.**, n. 95, p. 3549-3564, 1990.
- Gao, B. C., Heidebrecht, K. B. & Goetz, A. F. H. Derivation of scaled surface reflectances from AVIRIS data. **Remote Sensing of Environment**, v. 44, p. 165-178, 1993.
- Gates, D. M.; Keegan, H. J.; Chleter, J. C.; Weidner, V. R. Spectral properties of plants. **Applied Optics**, v. 4, n. 1, p. 11-20, 1965.
- Giardino, C.; Brando, V. E.; Dekker, A. G.; Strombeck, N.; Candiani, G. Assessment of water quality in Lake Garda (Italy) using Hyperion. **Remote Sensing of Environment**, v. 109, n. 2, p. 183-195, 2007.
- Gillespie, A. R.; Smith, M. O.; Adams, J. B.; Willis, S. C.; Fischer, A. F.; Sabol, D. E. Interpretation of residual images: spectral mixture analysis of AVIRIS images, Owens Valley, California. Proceedings of the Second Airborne Imaging Spectrometer Data Analysis Conference (p. 243-270). Pasadena, CA: Jet Propulsion Laboratory. 1990.
- Goetz, A.F.H.; Vane, G.; Solomon, J.E.; Rock, B.N. Imaging spectrometry for Earth remote sensing. **Science**, v. 228, n. 4704, p. 1147-1153, 1985.
- Goodenough, D.G.; Bhogal, A.S.; Dyk, A.; Hollinger, A.; Mah, Z.; Niemann, K.O.; Pearlman, J.; Chen, H.; Tan, T.; Love, J.; McDonald, S. Monitoring forest with

- Hyperion and ALI. **IEEE Transactions on Geoscience and Remote Sensing**, v. 2, p. 882-885, 2002.
- Goodenough, D. G.; Dyk, A.; Niemann, K. O.; Pearlman, J. S.; Chen, H.; Han, T.; Murdoch, M.; West, C. Processing Hyperion and ALI for Forest Classification. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 6, p. 1321-1331, 2003.
- Green, A. A.; Berman, M.; Switzer, P.; Craig, M. D. A transformation for ordering multispectral data in terms of image quality with implications for noise removal. **IEEE Transactions on Geoscience and Remote Sensing**, v. 26, n. 1, p. 65-74, 1988.
- Green, R. O. Retrieval of Reflectance from Calibrated Radiance Imagery Measured by the Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) for Lithological Mapping of Clark Mountains, California, in: *Proceedings of the Second Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) Workshop*, JPL Publ. 90-54, Jet Propulsion Laboratory, Pasadena, CA, v. 1, p. 167-175, 1990.
- Green, R. O. Estimation of biomass fire temperature and areal extent from calibrated AVIRIS spectra: in Summaries of the 6th Annual JPL Airborne Earth Science Workshop, JPL Pub. v. 1. AVIRIS Workshop, Jet Propulsion Laboratory, California Institute of Technology, Pasadena, Calif., p. 105-114, 1996.
- Green, R. O. & Dozier, J. Retrieval of surface snow grain size and melt water from AVIRIS spectra. in Summaries of the 6th Annual JPL Airborne Earth Science Workshop, JPL Pub. 96-4, v. 1. AVIRIS Workshop, Jet Propulsion Laboratory, California Institute of Technology, Pasadena, Calif., p. 127-134, 1996.
- Green, R.O.; Eastwood, M.L.; Sarture, C.M.; Chrien, T.G.; Aronsson, M.; Chippendale, B.J.; Faust, J.A.; Pavri, B.E.; Chovit, C.J.; Solis, M.; Olah, M.R.; Williams, O. Imaging spectroscopy and the Airborne Visible/Infrared Imaging Spectrometer (AVIRIS). **Remote Sensing of Environment**, v. 65, n. 3, p. 227-248, Set. 1998.
- Hamilton, M. K.; Davis, C. O.; Rhea, W. J.; Pilorz, S. H.; Carder, K. L. Estimating chlorophyll content and bathymetry of Lake Tahoe using AVIRIS data. **Remote Sensing of Environment**, v. 44, n. 2-3, p. 217-230, 1993.
- Han, T.; Goodenough, D. G.; Dyk, A.; Love, J. Detection and Correction of Abnormal Pixels in Hyperion Images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 3, p. 1327-1330, 2002.
- Horwitz H.M., Nalepka R.F., Hyde P.D., Morgenstern J.P. Estimating the proportions of objects within a single resolution element of a multispectral scanner. Int'l Symp. Remote Sens. Environ. Ann Arbor, 7, *Proceedings*, 1307-1320, 1971.

- Horwitz H.M., Lewis J.T., Pentland A.P. Estimating proportions of objects from multispectral scanner data. Final Report, NSAS Contract NAS9-14123, NASA-CR-141862, 108p, 1975.
- Huete A.R. Separation of soil-plant spectral mixture by factor analysis. **Remote Sensing of Environment**, v. 19, n. 3, p. 237-251, 1986.
- Huete A.R.; Jackson R.D.; Post D.F. Spectral response of plant canopy with different soil backgrounds. **Remote Sensing of Environment**, v. 17, n. 37-53, 1986.
- Jensen, J. R. **Remote Sensing of the Environment: An Earth Resource Perspective**. New Jersey: Prentice Hall, 2000. 544 p.
- Johnson, J.R.; Staid, M.I.; Titus, T.N.; Becker, K. Shocked plagioclase signatures in Thermal Emission Spectrometer Data of Mars, Icarus, v. 180, p. 60-74, 2006.
- Jupp, D.L.B. & Bisun, D. **Evaluation of Hyperion Performance at Australian Hyperspectral Calibration and Validation Sites (NRA-99-0ES-01)**. 2001. Disponível em: <http://www.cossa.csiro.au/hswwww/oz_pi/ozpi.htm>. Acesso em: 04 de março. 2007.
- Kim, S. H.; Kang, S. J.; Chi, J. H.; Lee, K. S. Absolute Atmospheric Correction Procedure for the EO-1 Hyperion Data Using MODTRAN Code. **Korean Journal of Remote Sensing**, v. 23, n. 1, p. 7-14. 2007.
- Kindel, B.; Qu, Z.; Goetz, A.F.H. Hyperspectral solar radiometry for surface reflectance retrieval. *Proceedings of the Ninth AVIRIS Earth Science and Applications Workshop*, JPL Publication 00-18, 2000.
- Kollenkark, J. C.; Vanderbilt, V. C.; Bauer, M. E.; Housley, T. L. Effect of cultural practices on agronomic and reflectance characteristics of soybean canopy. *Agronomy Journal*, v. 74, n. 4, p. 751-8, 1982.
- Kruse, F. A.; Lefkoff, A. B.; Boardman, J. W.; Heidebrecht, K. B.; Shapiro, A. T.; Barloon, P. J.; A.F.H., G. The spectral Image-Processing System (Sips) – interactive visualization and analysis of imaging spectrometer data. **Remote Sensing of Environment**, v. 44, n.2-3, p. 145-163, 1993.
- Kruse, F. A.; Lefkoff, A. B.; Dietz, J. B. Expert System-Based Mineral Mapping in northern Death Valley, California/Nevada using the Airborne Visible/Infrared Imaging Spectromete (AVIRIS). **Remote Sensing of Environment**, v. 44, p. 309 – 336, 1993a. Disponível em: http://www.hgimaging.com/PDF/Kruse_Xpert93_NGM_RSE.pdf>. Acesso em: 12 set. 2006.
- Kruse, F. A. Geologic mapping using combined optical remote sensing and SIR-C/X-SAR data. In: Thematic Conference and Workshops on Applied Geologic Remote Sensing, 11, Las Vegas, Nevada. v. 2, p. 142-150, 1996.

- Kruse, F. A. Characterization of active hot-springs environments using multispectral and hyperspectral remote sensing: in proceedings, 12th Thematic Conference, Applied Geologic Remote Sensing, 17-19 November 1997, Environmental Research Institute of Michigan (ERIM), Ann Arbor, MI, p. I-214 – I-221. 1997.
- Kruse, F. A. Mapping hot spring deposits with AVIRIS at Steamboat Springs, Nevada. In: JPL Airborne Earth Science Workshop, 8, Pasadena, CA. Summaries, JPL Publ. 99-17. v. 1, p. 239-245, 1999.
- Kruse, F. A.; Boardman, J. W.; Huntington, J. F.; Mason, P.; Quigley, M.A. Evaluation and Validation of EO-1 Hyperion for Geologic Mapping. IGARSS 2002, 24 – 28 June 2002, Toronto, Canada, Published on CD ROM – Paper 02_06. Disponível em:
<http://www.hgimaging.com/PDF/Kruse_IGARSS2002_Hyperion.pdf>. Acesso em 21 ser. 2006.
- Kruse, F. A.; Boardman, J. W.; Huntington, J. F. Comparison of Airborne Hyperspectral Data and EO-1 Hyperion for Mineral Mapping: in Special Issue. **Transactions on Geoscience and Remote Sensing (TGARS)**, IEEE, v. 41, n. 6, p. 1388 – 1400, 2003.
- Kruse, F. A., 2003a, Mineral Mapping with AVIRIS and EO-1 Hyperion: In proceedings 12th JPL Airborne Geoscience Workshop, Jet Propulsion Laboratory Publication 04-6 (CD-ROM), p. 149 - 156. Disponível em:
<http://www.hgimaging.com/PDF/Kruse_JPL2003_Minerals.pdf> Acesso em: 21 out. 2006.
- Kruse, F. A. Comparison of ATREM, ACORN, and FLAASH Atmospheric Corrections using Low-Altitude AVIRIS Data of Boulder, Colorado: In proceedings 13th JPL Airborne Geoscience Workshop, Jet Propulsion Laboratory, 31 March – 2 April 2004, Pasadena, CA, JPL Publication 05-3. Disponível em: <ftp://popo.jpl.nasa.gov/pub/docs/workshops/04_docs/Kruse-> Acesso em: 19 nov. 2006.
- Latorre, M.; Carvalho Junior, O. A.; Carvalho, A. P.; Shimabukuro, Y. E. Correção atmosférica: Conceitos e Fundamentos, 2002. Disponível em:
<http://www.unb.br/ih/novo_portal/portal_gea/lsie/revista/arquivos/volume_5_numero_1_2002/e_g_2002_v5_n1_153_178_latorre_et_al.pdf> Acesso em: 13 abr. 2008.
- Li, L. & Mustard, J.F. Highland contamination in lunar mare soils: Improved mapping with multiple end-member spectral mixture analysis. **Journal of Geophysical Research**, v. 108, doi: 10.1029/2002JE001917.5033, 2003.
- Lillesand, T. M.; Kiefer, R. W., Chipman, J. W. **Remote sensing and image interpretation**. 5. ed. New York: John Wiley & Sons, 2004. 763 p.
- Moreira, M. A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. 2. ed. Viçosa: UFV, 2003. 307p.

- Mustard, J. F. Relationships of soil, grass, and bedrock over the Kaweah Serpentinite Melange through spectral mixture analysis of AVIRIS data. **Remote Sensing of Environment**, 44:293-308, 1993.
- Mustard, J. F. & Head, J. W. Mare-highland mixing relationships along the southwestern shores of Oceanus Procellarum. *J. Geophys. Res.*, v. 101, p. 18913-18925, 1996.
- Nolin, W. & Dozier, J. Estimating snow grain size using AVIRIS data. **Remote Sensing of Environment**, v. 44, n. 2-3, p. 231 – 238, 1993.
- Novo, E.M.L.M. **Sensoriamento remoto: princípios e aplicações**. 3. ed. São Paulo: Edgard Blucher, 1992. 308p.
- Numata, I.; Roberts, D. A.; Chadwick, O. A.; Schimel, J. P.; Galvão, L. S.; Soares, J. V. Evaluation of hyperspectral data for pasture estimate in the Brazil Amazon using Field and imaging spectrometers. **Remote Sensing of Environment**, v. 112, n. 4, p. 1569-1583, 2008.
- Okin G. S.; Okin W. J.; Roberts D. A.; Murray B. Multiple Endmember Spectral Mixture Analysis: application to an arid/semiarid landscape. *JPL Airborne Earth Science Workshop*, 7, Pasadena, CA, *Summaries*, JPL Publ. v. 97, n. 21, p. 291-299, 1998.
- Okin, G. S.; Roberts, D. A.; Murray, B.; Okin, W. J. Practical limits on hyperspectral vegetation discrimination in arid and semiarid environments. **Remote Sensing of Environment**, n. 77, p. 212–225, 2001.
- Painter, T.H.; Roberts, D.A.; Green, R.O.; Dozier, J. The Effect of Grain Size on Spectral Mixture Analysis of Snow-covered Area from AVIRIS Data. **Remote Sensing of Environment**, v. 65, p. 320-332, 1998.
- Painter, T.H.; Dozier, J.; Roberts, D.A.; Davis, R.E.; Green, R.O. Retrieval of Subpixel Snow-covered Area and Grain Size from Imaging Spectrometer Data. **Remote Sensing of Environment**, v. 85, p. 64-77, 2003.
- Pearlman, J.; Seagal, C.; Liao, L.; Carman, S.; Folkman, M.; Browe, B.; Ong, L.; Ungar, S. **Development and Operations of the EO-1 Hyperion Imaging Spectrometer**. 2000. Disponível em: <<http://eol.gsfc.nasa.gov/miscPages/TechForumOther/Hyperion%20SPIE%20Publication.pdf>> Acesso em: 24 nov. 2006.
- Pereira, J.L.G.; Batista, G.T.; Thales, M.C.; Roberts, D.A. 1998. Proporção de componentes derivadas de imagens Landsat TM para caracterização da cobertura da terra na amazônia. (CD ROM). *In: Simpósio Brasileiro de Sensoriamento Remoto, Santos.CD ROM Anais*.
- Peterson, D. L.; Aber, J. D.; Matson, P. A.; Card, D. H.; Swanberg, N.; Wessman, C.; Spanner, M. Remote sensing of forest canopy and leaf biochemical contents. **Remote Sensing of Environment**, v. 24, n. 1, p. 85 – 108, 1988.

- Ponzoni, J. F. & Shimabukuro, Y. E. **Sensoriamento Remoto no Estudo da Vegetação**. 1. ed. São José dos Campos: A. Silva Vieira Ed., 2007. 127 p.
- Powell, R.; Roberts, D.A.; Dennison, P.E.; Hess, L.L. Sub-pixel mapping of urban land cover using multiple endmember spectral mixture analysis: Manaus, Brazil. **Remote Sensing of Environment**, v. 106, p. 253-267, 2007.
- Qu, Z.; Goetz, A.F.H.; Kindel, B. High-accuracy Atmospheric Correction for Hyperspectral Data (HATCH). *Proceedings of the Ninth AVIRIS Earth Science and Applications Workshop*, JPL Publication 00-18, p. 373-380, Jet Propulsion Laboratory, Pasadena, CA., 2000
- Rambo, B. **A Fisionomia do Rio Grande do Sul: ensaio de monografia natural**. 3. ed. São Leopoldo: UNISINOS Ed., 1994.
- Rashed, T.; Weeks, J.R.; Roberts, D.; Rogan, J.; Powell, R. Measuring the Physical Composition of Urban Morphology using Multiple Endmember Spectral Mixture Models, **Photogramm. Eng. Remote Sens.** V. 69, n. 9, p. 1011-1020, 2003.
- Ray, T.W. & Murray, B.C. Nonlinear spectral mixing in desert vegetation. **Remote Sensing of Environment**, v. 55, p. 59-64, 1996.
- Reinart, A.; Kutser, T. Comparison of different satellite sensors in detecting cyanobacterial bloom events in the Baltic Sea. **Remote Sensing of Environment**, v. 102, n. 1-2, p. 74-85, 2006.
- Richards, A. R. & Jia, X. **Remote sensing digital image analysis: an introduction**. 4th. ed. Berlin: Springer-Verlag. 2006. 439 p.
- Richardson A.J.; Wiegand C.L.; Gausman H.W.; Cuellar J.A.; Genermann A.H. Plant, soil and shadow reflectance components of row crops. **Photogramm. Eng. Remote Sens.**, n. 41, p. 1401-1407, 1975.
- Richardson, L. L.; Buison, D.; Lui, C. J.; Ambrosia, V. The detection of algal photosynthetic accessory pigments using Airborne Visible-Infrared Imaging Spectrometer (AVIRIS) spectral data. *Marine Technology Society Journal*, v. 28, p. 10-21, 1994.
- Richardson, L. L. Remote sensing of algal bloom dynamics. **Bio Science**, v. 46, n. 7, p. 492-501, 1996.
- Roberts, D. A.; Smith, M. O.; Sabol, D. E.; Adams, J. B., Ustin, S. Mapping the Spectral variability in photosynthetic and non-photosynthetic vegetation, soils and shade using AVIRIS. In: Annual JPL Airborne Geoscience Workshop, 3, Pasadena, CA. *Proceedings*, JPL Publ. v. 92, n. 14, p. 38-40, 1992.
- Roberts, D.A.; Adams, J.B.; Smith, M.O. Discriminating Green Vegetation, Non-Photosynthetic Vegetation and Soils in AVIRIS Data. **Remote Sensing of Environment**, v. 44, n. 2-3, p. 255-270, 1993.

- Roberts, D. A.; Green, R. O.; Sabol, D. E.; Adams, J. B. Temporal Changes I Endmember Abundances, Liquid Water and Water Vapor Over Vegetation at Jasper Ridge. In: Annual JPL Geoscience Workshop, 4, Pasadena, CA. *Proceedings*, JPL Publ. 93-96, p.153-156, 1993.
- Roberts, D. A.; Green, R. O.; Adams, J. B. Temporal and spatial patterns in vegetation and atmospheric properties from AVIRIS. **Remote Sensing of Environment**, v. 62, n. 3, p. 223-240, 1997.
- Roberts D.A.; Gardner M.; Church R.; Ustin S.; Scheer G.; Green R.O. Mapping chaparral in the Santa Monica Mountains using multiple endmember spectral mixture models. **Remote Sensing of Environment**, v. 65, n. 3, p. 267-279, 1998a.
- Roberts, D. A.; Keller, M.; Soares, J. V. Studies of land-cover, land-use, and biophysical properties of vegetation in Large Scale Biosphere Atmosphere experiment in Amazonia. **Remote Sensing of Environment**, v. 87, n. 4, p. 377-388, 2003.
- Roberts, D. A.; Halligan, K.; Dennison, P. **VIPER Tools User Manual**. Versão 1.2. Santa Barbara: University of Califórnia Santa Barbara, 2007 p. 95. Disponível em: <<http://www.vipertools.org/download.html>> Acesso em: 18 abr. 2007.
- Roberts, D. A. Advanced Analysis of Imaging Spectrometry. 2007. CD-ROM
- Rosso, P. H.; Ustin, S. L.; Hastings, A. Mapping marshland vegetation of San Francisco Bay, Califórnia, using hyperspectral data. **International Journal of Remote Sensing**. v. 26, n23, p. 5169-5191, 2005.
- Rudorff, C. M. **Estudo da Composição das Águas da Planície Amazônica por meio de dados de reflectância do sensor Hyperion/EO-1 e de espectrômetro de campo visando à compreensão da variação temporal dos seus constituintes opticamente ativos** São José dos Campos: INPE, 2006. 143 p. Dissertação (Mestrado) – Programa de Pós-Graduação em Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006.
- Sabol, D. E. JR.; Roberts, D. A.; Smith, M. O.; Adams, J. B. Temporal variation in spectral detection thresholds of substrate and vegetation in AVIRIS images. In: Annual JPL Airborne Geoscience Workshop, 3, Pasadena, CA. *Proceedings*, JPL Publ. v. 92, n. 14, p.132-134, 1992b.
- Sabol, D. E. Jr.; Smith, M. O.; Adams, J. B.; Gillespie, A. R.; Tucker, C. J. Monitoring forest regrowth using a multi-platform time series. in Summaries of the 6th Annual JPL Airborne Earth Science Workshop, JPL Pub. 96-4, Vol. 1. AVIRIS Workshop, Jet Propulsion Laboratory, California Institute of Technology, Pasadena, Calif., p. 203-208, 1996.
- Shimabukuro, Y.E. & Smith, J.A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 29, n.1, p. 16-20, 1991.

- Singer, R. & Mccord, T. B. Mars: large scale mixing of bright and dark surface materials and implication for analysis of spectral reflectance. Lunar Planet Sci. Conf., 10, Proceedings, p. 1835-1848, 1979.
- Smith, P. S.; Balonek, T. J.; Heckert, P. A.; Elston, R.; Schmidt, G. D. UBVRI field comparison stars for selected active quasars and BL Lacertae objects. **Astronomical Journal**, v. 90, p. 1184-1187, 1985.
- Smith, M.O. & Adams J.B. Interpretation of AIS images of Cuprite, Nevada, using constrains of spectral mixtures. *In: Proceedings of the Airborne Imaging Spectrometer Data Analysis Workshop, Pasadena, CA, JPL Publ. n. 85, v. 41, p. 62-68, 1985.*
- Smith, M. O.; Adams, J. B.; Ustin, S. L.; Roberts, D. A. Using endmembers in AVIRIS images to estimate changes in vegetative biomass. *In: Annual JPL Airborne Geoscience Workshop, 4, Pasadena, CA. Proceedings, JPL Publ. v. 92, n. 14, p. 69-71, 1992.*
- Steffen, C. A.; Gama, F. F.; Novo, E. M. L. M. **Teste operacional de aquisição de dados aerotransportados – SADA, o experimento de Barra Bonita.** São José dos Campos, SP:INPE, 1992.
- Stoner, E. R. & Baumgardner, M. F. Physiochemical, Site Bidirectional Reflectance Factor Characteristics of Uniformly Moist Soils. West Lafayette (LARS Technical Report 111679) Purdue University, p. 94, 1980.
- Tanré, D., Deroo, C., Duhaut, P. et al. Description of a computer code to simulate the satellite signal in the solar spectrum: The 5S code. **Int. J. Remote Sensing**, v.11, n. 4, p. 659-668, 1990.
- Teixeira, C. G. **Validação do modelo linear de mistura espectral em imagens ASTER/TERRA a partir de dados IKONOS.** São José dos Campos: INPE, 2004. 127 p. Dissertação (Mestrado) – Programa de Pós-Graduação em Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2004.
- Tisot, D. A.; Formaggio, A. R.; Galvão, L. S.; Rennó, C. D. Dados Hyperion e ETM+ na classificação de alvos agrícolas com diferentes níveis de distinção espectral. *In: Simpósio Brasileiro de Sensoriamento Remoto, 12. (SBSR), 16-21 abr. 2005, Goiânia. Anais... São José dos Campos: INPE, 2005. Artigos, p. 439-446. CD-ROM*
- Tomazelli, L. J.; Villwock, J. A. **Mapeamento Geológico de Planícies Costeiras: o Exemplo da Costa do Rio Grande do Sul.** GRAVEL. 2005.
- Tompkins, S.; Mustard, J. F.; Pieters, C. M.; Forsyth, D. W. Optimization of endmembers for spectral mixture analysis. **Remote Sensing of Environment**, 59, 472-489, 1997.

- Ustin, S. L.; Smith, M. O.; Adams, J. B. Multitemporal diurnal AVIRIS images of a forested ecosystem. In: Annual JPL Airborne Geoscience Workshop, 4, Pasadena, CA. *Proceedings*, JPL Publ. v. 92, n. 14, p.141-143, 1992.
- Vane G., Chrisp M., Enmark H., Macenka S., Solomon J. 1984. Airborne Visible/Infrared Imaging Spectrometer (AVIRIS): an advanced tool for earth remote sensing. In: IEEE Int. Geosci. Remote Sensing Symp., IEEE, New York, *Proceedings*, SP215, 751-757.
- Vasconcelos, C. H.; Novo, E. M. L. Mapeamento do uso e cobertura da terra a partir da segmentação e classificação de imagens – fração solo, sombra e vegetação derivadas do modelo linear de mistura aplicado a dados do sensor TM/Landsat 5, na região do reservatório de Tucuruí – PA. **ACTA Amazônica**, v. 34, n. 3, p. 487-493, 2004.
- Villwock, J.A. Geology of the Coastal Province of Rio Grande do Sul, Southern Brazil, Southern Brazil. Pesquisas (16). Porto Alegre: UFRGS, p. 5-49, 1984.
- Villwock, J.A; Tomazelli, L.J.; Loss, E.L.; Dehnhardt, E.A.; Horn Filho, N.O.; Bachi, F.A.; Dehnhardt, B.A. Geology of the Rio Grande do Sul coastal province. In: Rebassa, J. (ed.). Quaternary of South America and Antarctic Peninsula. A.A., Rotterdam. v. 4, p. 79-97, 1986.
- Villwock, J. A.; Tomazelli, L. J.; Loss, E. L.; Dehnhardt, E. A.; Bachi, F. A.; Dehnhardt, B. A.; Godolphim, M. F.; Horn Filho, N. O. **Mapa geológico da Província Costeira do Rio Grande do Sul – Escala: 1:1.000.000**. Porto Alegre, 1994. CECO – Instituto de Geociências. Universidade Federal do Rio Grande do Sul. Porto Alegre, RS. 1994. Mapa.
- Villwock, J. A. & Tomazelli, L. J. Geologia costeira do Rio Grande do Sul. Notas Técnicas (8). Porto Alegre: UFRGS, 1995. p.1-45.
- Walsh, S. J.; McCleary, A. L.; Mena, C. F.; Shao, Y.; Tuttle, J. P.; Gonzalez, A.; Atkinson, R. QuickBird and Hyperion data analysis of an invasive plant species in the Galapagos Islands of Ecuador: Implications for Control and land use management. **Remote Sensing of Environment**, v. 112, n. 5, p. 1927-1941, 2008.

APÊNDICE A

BANDAS ESPECTRAIS DO SENSOR HYPERION

Bandas	Comprimento de onda (nm)	Largura de banda (FWHM) (nm)	Bandas	Comprimento de onda (nm)	Largura de banda (FWHM) (nm)
B1*	355.5900	11.3871	B41	762.6000	10.7276
B2	365.7600	11.3871	B42	772.7800	10.7907
B3	375.9400	11.3871	B43	782.9500	10.8833
B4	386.1100	11.3871	B44	793.1300	10.9938
B5	396.2900	11.3871	B45	803.3000	11.1044
B6	406.4600	11.3871	B46	813.4800	11.1980
B7	416.6400	11.3871	B47	823.6500	11.2600
B8**	426.8200	11.3871	B48	833.8300	11.2824
B9	436.9900	11.3871	B49	844.0000	11.2822
B10	447.1700	11.3871	B71	851.9200	11.0457
B11	457.3400	11.3871	B50	854.1800	11.2816
B12	467.5200	11.3871	B72	862.0100	11.0457
B13	477.6900	11.3871	B51	864.3500	11.2809
B14	487.8700	11.3784	B73	872.1000	11.0457
B15	498.0400	11.3538	B52	874.5300	11.2797
B16	508.2200	11.3133	B74	882.1900	11.0457
B17	518.3900	11.2580	B53	884.7000	11.2782
B18	528.5700	11.1907	B75	892.2800	11.0457
B19	538.7400	11.1119	B54	894.8800	11.2771
B20	548.9200	11.0245	B76	902.3600	11.0457
B21	559.0900	10.9321	B55	905.0500	11.2765
B22	569.2700	10.8368	B77	912.4500	11.0457
B23	579.4500	10.7407	B56	915.2300	11.2756
B24	589.6200	10.6482	B78	922.5400	11.0457
B25	599.8000	10.5607	B57	925.4100	11.2754
B26	609.9700	10.4823	B79	932.6400	11.0457
B27	620.1500	10.4147	B58	935.5800	11.2754
B28	630.3200	10.3595	B80	942.7300	11.0457
B29	640.5000	10.3188	B59	945.7600	11.2754
B30	650.6700	10.2942	B81	952.8200	11.0457
B31	660.8500	10.2856	B60	955.9300	11.2754
B32	671.0200	10.2980	B82	962.9100	11.0457
B33	681.2000	10.3349	B61	966.1100	11.2754
B34	691.3700	10.3909	B83	972.9900	11.0457
B35	701.5500	10.4592	B62	976.2800	11.2754
B36	711.7200	10.5322	B84	983.0800	11.0457
B37	721.9000	10.6004	B63	986.4600	11.2754
B38	732.0700	10.6562	B85	993.1700	11.0457
B39	742.2500	10.6933	B64	996.6300	11.2754
B40	752.4300	10.7058	B86	1003.3000	11.0457

Bandas	Comprimento de onda (nm)	Largura de banda (FWHM) (nm)	Bandas	Comprimento de onda (nm)	Largura de banda (FWHM) (nm)
B65	1006.8100	11.2754	B121	1356.3500	10.7163
B87	1013.3000	11.0457	B122	1366.4500	10.7283
B66	1016.9800	11.2754	B123	1376.5500	10.7437
B88	1023.4000	11.0451	B124	1386.6500	10.7612
B67	1027.1600	11.2754	B125	1396.7400	10.7807
B89	1033.4900	11.0423	B126	1406.8400	10.8034
B68	1037.3300	11.2754	B127	1416.9400	10.8267
B90	1043.5900	11.0372	B128	1426.9400	10.8534
B69	1047.5100	11.2754	B129	1437.0400	10.8818
B91	1053.6900	11.0302	B130	1447.1400	10.9110
B70	1057.6800	11.2754	B131	1457.2300	10.9422
B92	1063.7900	11.0218	B132	1467.3300	10.9743
B93	1073.8900	11.0122	B133	1477.4300	11.0074
B94	1083.9900	11.0013	B134	1487.5300	11.0414
B95	1094.0900	10.9871	B135	1497.6300	11.0759
B96	1104.1900	10.9732	B136	1507.7300	11.1108
B97	1114.1900	10.9572	B137	1517.8300	11.1461
B98	1124.2800	10.9418	B138	1527.9200	11.1811
B99	1134.3800	10.9248	B139	1537.9200	11.2156
B100	1144.4800	10.9065	B140	1548.0200	11.2496
B101	1154.5800	10.8884	B141	1558.1200	11.2826
B102	1164.6800	10.8696	B142	1568.2200	11.3146
B103	1174.7700	10.8513	B143	1578.3200	11.3460
B104	1184.8700	10.8335	B144	1588.4200	11.3753
B105	1194.9700	10.8154	B145	1598.5100	11.4037
B106	1205.0700	10.7979	B146	1608.6100	11.4302
B107	1215.1700	10.7822	B147	1618.7100	11.4538
B108	1225.1700	10.7663	B148	1628.8100	11.4760
B109	1235.2700	10.7520	B149	1638.8100	11.4958
B110	1245.3600	10.7385	B150	1648.9000	11.5133
B111	1255.4600	10.7270	B151	1659.0000	11.5286
B112	1265.5600	10.7174	B152	1669.1000	11.5404
B113	1275.6600	10.7091	B153	1679.2000	11.5505
B114	1285.7600	10.7022	B154	1689.3000	11.5580
B115	1295.8600	10.6970	B155	1699.4000	11.5621
B116	1305.9600	10.6946	B156	1709.5000	11.5634
B117	1316.0500	10.6937	B157	1719.6000	11.5617
B118	1326.0500	10.6949	B158	1729.7000	11.5563
B119	1336.1500	10.6996	B159	1739.7000	11.5477
B120	1346.2500	10.7058	B160	1749.7900	11.5346

Bandas	Comprimento de onda (nm)	Largura de banda (FWHM) (nm)	Bandas	Comprimento de onda (nm)	Largura de banda (FWHM) (nm)
B161	1759.8900	11.5193	B202	2173.5300	10.6312
B162	1769.9900	11.5002	B203	2183.6300	10.6052
B163	1780.0900	11.4789	B204	2193.7300	10.5803
B164	1790.1900	11.4548	B205	2203.8300	10.5560
B165	1800.2900	11.4279	B206	2213.9300	10.5328
B166	1810.3800	11.3994	B207	2224.0300	10.5101
B167	1820.4800	11.3688	B208	2234.1200	10.4904
B168	1830.5800	11.3366	B209	2244.2200	10.4722
B169	1840.5800	11.3036	B210	2254.2200	10.4552
B170	1850.6800	11.2696	B211	2264.3200	10.4408
B171	1860.7800	11.2363	B212	2274.4200	10.4285
B172	1870.8700	11.2007	B213	2284.5200	10.4197
B173	1880.9800	11.1666	B214	2294.6100	10.4129
B174	1891.0700	11.1333	B215	2304.7100	10.4088
B175	1901.1700	11.1018	B216	2314.8100	10.4077
B176	1911.2700	11.0714	B217	2324.9100	10.4077
B177	1921.3700	11.0424	B218	2335.0100	10.4077
B178	1931.4700	11.0155	B219	2345.1100	10.4077
B179	1941.5700	10.9912	B220	2355.2100	10.4077
B180	1951.5700	10.9698	B221	2365.2000	10.4077
B181	1961.6600	10.9508	B222	2375.3000	10.4077
B182	1971.7600	10.9355	B223	2385.4000	10.4077
B183	1981.8600	10.9230	B224	2395.5000	10.4077
B184	1991.9600	10.9139	B225	2405.6000	10.4077
B185	2002.0600	10.9083	B226	2415.7000	10.4077
B186	2012.1500	10.9069	B227	2425.8000	10.4077
B187	2022.2500	10.9057	B228	2435.8900	10.4077
B188	2032.3500	10.9013	B229	2445.9900	10.4077
B189	2042.4500	10.8951	B230	2456.0900	10.4077
B190	2052.4500	10.8854	B231	2466.0900	10.4077
B191	2062.5500	10.8740	B232	2476.1900	10.4077
B192	2072.6500	10.8591	B233	2486.2900	10.4077
B193	2082.7500	10.8429	B234	2496.3900	10.4077
B194	2092.8400	10.8242	B235	2506.4800	10.4077
B195	2102.9400	10.8039	B236	2516.5900	10.4077
B196	2113.0400	10.7820	B237	2526.6800	10.4077
B197	2123.1400	10.7592	B238	2536.7800	10.4077
B198	2133.2400	10.7342	B239	2546.8800	10.4077
B199	2143.3400	10.7092	B240	2556.9800	10.4077
B200	2153.3400	10.6834	B241	2566.9800	10.4077
B201	2163.4300	10.6572	B242	2577.0800	10.4077

* - os intervalos em negrito foram excluídos do processamento por não possuírem informação no produto L1R do USGS.

** - os intervalos em vermelho foram excluídos por apresentarem forte absorção pelo vapor d'água ou presença de ruído.

APÊNDICE B

PONTOS COLETADOS EM CAMPO

GPS utilizado: Garmin 76

Projeção: UTM (Universal Transversa de Mercator)

Datum: WGS 84

Nome	Easting	Northing	Altitude	Data
Ponto 1	574501.387	6663131.906	3.010	3/30/2007 10:28:00 AM
Ponto 2	568919.698	6665013.898	9.258	3/30/2007 10:38:00 AM
Ponto 3	572423.713	6664405.792	4.452	3/30/2007 10:44:00 AM
Ponto 4	567831.427	6660743.222	12.142	3/30/2007 10:51:00 AM
Ponto 5	573898.549	6685668.369	5.173	3/30/2007 2:24:00 PM
Ponto 6	578543.466	6680946.699	-3.719	3/30/2007 2:59:00 PM
Ponto 7	572953.371	6681072.438	9.979	3/30/2007 3:14:00 PM
Ponto 8	574338.884	6684513.353	3.490	3/30/2007 3:32:00 PM
Ponto 9	573778.222	6675718.599	14.305	3/30/2007 5:55:00 PM
Ponto 10	572058.727	6677438.600	15.988	3/30/2007 6:09:00 PM
Ponto 11	575369.179	6659330.658	8.778	3/30/2007 9:06:00 AM
Ponto 12	571345.686	6674224.791	0.000	3/31/2007 1:03:00 PM
Ponto 13	571665.987	6673620.508	0.000	3/31/2007 1:07:00 PM
Ponto 14	571080.617	6671051.400	0.000	3/31/2007 1:15:00 PM
Ponto 15	570297.074	6665174.646	0.000	3/31/2007 1:30:00 PM
Ponto 16	570295.705	6665177.627	0.000	3/31/2007 10:30:00 AM
Ponto 17	574912.366	6662006.190	15.518	3/31/2007 10:40:53 PM
Ponto 18	573192.435	6663081.659	3.983	3/31/2007 10:42:40 PM
Ponto 19	568811.967	6661886.772	9.751	3/31/2007 10:58:59 PM
Ponto 20	568777.000	6661613.500	0.000	3/31/2007 10:59:32 PM
Ponto 21	569451.665	6661421.321	7.347	3/31/2007 11:00:05 PM
Ponto 22	575736.563	6681865.500	0.000	3/31/2007 11:02:53 PM
Ponto 23	573499.563	6675814.000	0.000	3/31/2007 11:05:47 PM
Ponto 24	572449.541	6679160.064	0.000	3/31/2007 12:50:00 PM
Ponto 25	577318.716	6693631.623	15.747	3/31/2007 2:18:00 PM
Ponto 26	578865.663	6694002.337	3.490	3/31/2007 3:27:00 PM
Ponto 27	579311.968	6700579.047	8.778	3/31/2007 3:50:00 PM
Ponto 28	578684.053	6700500.019	3.490	3/31/2007 3:52:00 PM
Ponto 29	576124.945	6689867.987	0.000	3/31/2007 4:38:00 PM
Ponto 30	581193.545	6692108.281	0.000	3/31/2007 5:38:00 PM
Ponto 31	580948.798	6690793.899	0.000	3/31/2007 5:43:00 PM
Ponto 32	581692.432	6689377.749	0.000	3/31/2007 5:49:00 PM
Ponto 33	582280.464	6687672.590	0.000	3/31/2007 6:00:00 PM
Ponto 34	583795.889	6695619.545	0.000	3/31/2007 6:39:00 PM
Ponto 35	577815.849	6698830.354	0.000	3/31/2007 6:56:00 PM
Ponto 36	573377.370	6678700.409	14.065	3/31/2007 7:22:00 PM

APÊNDICE C

ROTINA MATLAB

Rotina desenvolvida no MATLAB para geração das imagens fração de cada subclasse, tabela com o erro RMS para cada modelo MESMA e imagem contento a subclasse com maior fração para cada pixel.

```
clear all;

x4=load('endmember4.txt');

EM1_4= x4(1:900,:);
EM2_4= x4(901:1800,:);
EM3_4= x4(1801:2700,:);
SHADE_4= x4(2701:3600,:);
RMSE_4= x4(3601:4500,:);
MODELO_4= x4(4501:5400,:);

x=unique(MODELO_4);

a=zeros(900,256); % fracao maxima
b=zeros(900,256); % colunas maximas
c=zeros(900,256); % classes

tabela4=load('tabela4.txt');
nendmembers=4

for i=1:length(x)
    i
    Y=find(MODELO_4==x(i));

    for j=1:length(Y)
        [a(Y(j)),b(Y(j))]=max([EM1_4(Y(j)) EM2_4(Y(j)) EM3_4(Y(j))]);
    end

    if i>1
        fff=tabela4(i-1,2:nendmembers);
        c(Y)=fff(b(Y));
    end

    ERRO_4(i,1)= x(i);
    ERRO_4(i,2)= mean(RMSE_4(Y));

end

% geração das imagens fração

d=((c==20).*a);
e=((c==40).*a);
f=((c==60).*a);
```

```
g=((c==80).*a);
h=((c==100).*a);
i=((c==120).*a);
j=((c==140).*a);
k=((c==160).*a);

% comando para salvar

save 'fracao4.txt' a -ASCII -DOUBLE
save 'classes4.txt' c -ASCII -DOUBLE
save 'colunamaxima4.txt' b -ASCII -DOUBLE
save 'fracao20.txt' d -ASCII -DOUBLE
save 'fracao40.txt' e -ASCII -DOUBLE
save 'fracao60.txt' f -ASCII -DOUBLE
save 'fracao80.txt' g -ASCII -DOUBLE
save 'fracao100.txt' h -ASCII -DOUBLE
save 'fracao120.txt' i -ASCII -DOUBLE
save 'fracao140.txt' j -ASCII -DOUBLE
save 'fracao160.txt' k -ASCII -DOUBLE
```