



Ministério da  
Ciência e Tecnologia



INPE-15316-TDI/1360

## APLICAÇÃO DE DADOS HYPERION EO-1 NO ESTUDO DE PLANTAÇÕES DE EUCALYPTUS SPP

Vanessa Canavesi

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto,  
orientada pelo Dr. Flávio Jorge Ponzoni, aprovada em 9 de maio de 2008.

Registro do documento original:

<<http://urlib.net/sid.inpe.br/mtc-m18@80/2008/07.01.14.06>>

INPE  
São José dos Campos  
2008

## **PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3945-6911/6923

Fax: (012) 3945-6919

E-mail: [pubtc@sid.inpe.br](mailto:pubtc@sid.inpe.br)

## **CONSELHO DE EDITORAÇÃO:**

### **Presidente:**

Dr. Gerald Jean Francis Banon - Coordenação Observação da Terra (OBT)

### **Membros:**

Dr<sup>a</sup> Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação

Dr. Haroldo Fraga de Campos Velho - Centro de Tecnologias Especiais (CTE)

Dr<sup>a</sup> Inez Staciarini Batista - Coordenação Ciências Espaciais e Atmosféricas (CEA)

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Dr. Ralf Gielow - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

Dr. Wilson Yamaguti - Coordenação Engenharia e Tecnologia Espacial (ETE)

## **BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon - Coordenação de Observação da Terra (OBT)

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Jefferson Andrade Ancelmo - Serviço de Informação e Documentação (SID)

Simone A. Del-Ducca Barbedo - Serviço de Informação e Documentação (SID)

## **REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Marilúcia Santos Melo Cid - Serviço de Informação e Documentação (SID)

Yolanda Ribeiro da Silva e Souza - Serviço de Informação e Documentação (SID)

## **EDITORAÇÃO ELETRÔNICA:**

Viveca Sant´Ana Lemos - Serviço de Informação e Documentação (SID)



Ministério da  
Ciência e Tecnologia



INPE-15316-TDI/1360

## APLICAÇÃO DE DADOS HYPERION EO-1 NO ESTUDO DE PLANTAÇÕES DE EUCALYPTUS SPP

Vanessa Canavesi

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto,  
orientada pelo Dr. Flávio Jorge Ponzoni, aprovada em 9 de maio de 2008.

Registro do documento original:

<<http://urlib.net/sid.inpe.br/mtc-m18@80/2008/07.01.14.06>>

INPE  
São José dos Campos  
2008

Dados Internacionais de Catalogação na Publicação (CIP)

---

C16a Canavesi, Vanessa.

Aplicação de dados Hyperion EO-1 no estudo de plantações de eucalyptus spp/ Vanessa Canavesi. – São José dos Campos: INPE, 2008.

124p. ; (INPE-15316-TDI/1360)

1. Caracterização espectral. 2. Mapeamento da vegetação. 3. Volume de madeira. 4. Anisotropia da vegetação. 5. Quantificação de parâmetros biofísicos. I. Título.

CDU 528.711.7 (815.6)

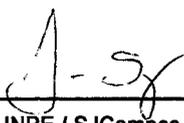
---

Copyright © 2008 do MCT/INPE. Nenhuma parte desta publicação pode ser reproduzida, armazenada em um sistema de recuperação, ou transmitida sob qualquer forma ou por qualquer meio, eletrônico, mecânico, fotográfico, microfílmico, reprográfico ou outros, sem a permissão escrita da Editora, com exceção de qualquer material fornecido especificamente no propósito de ser entrado e executado num sistema computacional, para o uso exclusivo do leitor da obra.

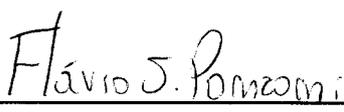
Copyright © 2008 by MCT/INPE. No part of this publication may be reproduced, stored in a retrieval system, or transmitted in any form or by any means, electronic, mechanical, photocopying, microfilming, recording or otherwise, without written permission from the Publisher, with the exception of any material supplied specifically for the purpose of being entered and executed on a computer system, for exclusive use of the reader of the work.

Aprovado (a) pela Banca Examinadora  
em cumprimento ao requisito exigido para  
obtenção do Título de Doutor(a) em  
Sensoriamento Remoto

Dr. Lênio Soares Galvão

  
\_\_\_\_\_  
Presidente / INPE / SJC Campos - SP

Dr. Flávio Jorge Ponzoni

  
\_\_\_\_\_  
Orientador(a) / INPE / SJC Campos - SP

Dr. Yosio Edemir Shimabukuro

  
\_\_\_\_\_  
Membro da Banca / INPE / SJC Campos - SP

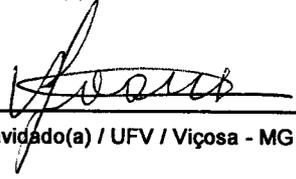
Dra. Evlyn Marcia Leão de Moraes Novo

  
\_\_\_\_\_  
Membro da Banca / INPE / SJC Campos - SP

Dr. Luis Marcelo Tavares de Carvalho

  
\_\_\_\_\_  
Convidado(a) / UFLA / Lavras - MG

Dr. Vicente Paulo Soares

  
\_\_\_\_\_  
Convidado(a) / UFV / Viçosa - MG

Aluno (a): Vanessa Canavesi

São José dos Campos, 09 de maio de 2008



*A minha família*  
*VICTOR*  
*MARIA JOSÉ E ALCIDES*  
*VIVIANE E ALINE*



## AGRADECIMENTOS

Ao meu orientador Prof. Dr. Flávio Jorge Ponzoni, por todo o ensinamento e tempo a mim dedicado e pela grande amizade.

A meus pais, pelo apoio incondicional durante a minha vida toda.

A meu filho Victor, por todas as alegrias que me causou desde o seu nascimento.

Às minhas irmãs, que sempre tiveram ao meu lado.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq, pelo auxílio financeiro de quatro anos de bolsa de doutorado.

Ao Instituto Nacional de Pesquisas Espaciais – INPE, pela oportunidade de estudos e utilização de suas instalações.

Ao Prof. Dr. Márcio Morisson Valeriano, pelos dados SRTM cedidos e pela ajuda imensa na preparação dos dados topográficos e geração da equação do fator de iluminação.

Ao Prof. Dr. Lênio Soares Galvão, pelo auxílio com as imagens hiperespectrais e por todas as vezes que me recebeu e me aconselhou no decorrer da minha tese.

À empresa Votorantim Celulose e Papel por fornecer o local de trabalho, bem como dados referentes aos plantios. Por ceder também os engenheiros Sebastião Ferreira e Eduardo Valente para nos acompanhar nos trabalhos de campo e por toda a ajuda que nos deram a respeito dos talhões para a montagem do banco de dados.

À empresa Martins Florestal por ceder o técnico Amarildo, quem nos acompanhou no campo e auxiliou nas medições dos talhões.

A todos os meus amigos do curso de pós-graduação de 2004, especialmente Samuel, Silvana, Ilka, Mônica, Michele, Camilas... e todos aqueles que tornaram a minha jornada mais alegre.

Aos amigos Poly, Arnaldo, Cleber, Igor e Luciana, pelos bons conselhos.

Aos amigos Antônio Correia e Rogério pelo desenvolvimento das programações em IDL.

Aos amigos Veraldo e Conrado pelas idéias compartilhadas sobre o tema da tese.

À querida Etel, pela amizade de quatro anos, durante os quais trocamos idéias, conselhos e muitas risadas.

À Vera e Lucas pelo apoio na pós-graduação do SERE.

A meu namorado Marcellus que me acompanhou nesses 4 anos de curso me apoiando em todos os momentos.

## RESUMO

A disponibilidade de dados hiperespectrais trouxe expectativas nos meios acadêmicos e empresariais quanto à potencialidade de sua aplicação no setor florestal. O objetivo deste trabalho foi avaliar o potencial da aplicação de dados hiperespectrais do sensor Hyperion EO-1 na quantificação da variável biofísica volume de madeira de plantios de *Eucalyptus* spp. estabelecimento de correlações entre dados espectrais e volume de madeira, seguido da definição de modelos de regressão linear múltipla como descritores das relações estabelecidas. Nas duas abordagens o efeito do relevo sobre a reflectância dos dosséis de *Eucalyptus* spp. foi levado em consideração. Os dados Hyperion EO-1 foram convertidos para valores de FRB de superfície, os quais passaram a constituir os dados fundamentais de todo o trabalho. A área de estudo contemplou os plantios do gênero *Eucalyptus* spp., pertencentes à empresa Votorantim Celulose e Papel, localizados no município de Capão Bonito-SP. Foram utilizados dados do sensor Hyperion e foram simulados dados dos sensores TM e HRV, presentes nos satélites Landsat e Spot, respectivamente, a partir dos dados Hyperion. Nas classificações ficou evidente o efeito da arquitetura do dossel na diferenciação das idades dos plantios, em detrimento de uma desejada individualização de espécies. Essa diferenciação foi facilitada quando a anisotropia dos plantios era levada em consideração. No estabelecimento das relações com volume de madeira, a possibilidade de cálculo de índices de vegetação mediante o emprego de dados hiperespectrais implicou em modelos com maiores valores de  $R^2$ , comprovando maior potencial de aplicação em avaliações do gênero.



## APPLICATION OF HYPERIN EO-1 DATA IN *Eucalyptus* spp. PLANTATIONS.

### ABSTRACT

The access to orbital hyperspectral data has offered new perspectives to both academic and corporative sectors in terms of their potential to solve some demands in the forestry science. The main objective here was to evaluate the potential and constrains of the hyperspectral data from the Hyperion EO-1 sensor in the *Eucalyptus* spp. stands study. Two approaches were adopted. The first one was based on a species classification procedure and the second one included evaluations of the relationship between the spectral data and the stand logging. It was defined some multiple linear regression models as descriptors of that relationship. In both approaches the relief effect on the *Eucalyptus* spp. canopy reflectance was taken into account. The Hyperion EO-1 data were converted to BRDF surface values, which were considered the basis of the entire work. The study area was located in Capão Bonito city (São Paulo State, Brazil) and included *Eucalyptus* spp. stands managed by the Votorantin Papel e Celulose company. Multi-spectral data of TM/Landsat and HRV/SPOT sensors were simulated from the Hyperion EO-1 ones. In the classification evaluation it was evident the canopy architecture effect in the stand age differentiation despite the species identification. This identification has been improved when the vegetation anisotropy was taken into account. In volume x radiometric data relationship evaluation the vegetation indices calculated from the hyperspectral data increase the  $R^2$  values that were interpreted as an advantage comparing to the multi-spectral data in this kind of evaluation.



## SUMÁRIO

Pág.

LISTA DE FIGURAS

LISTA DE TABELAS

<b>1 INTRODUÇÃO .....</b>	<b>19</b>
<b>2 FUNDAMENTAÇÃO TEÓRICA.....</b>	<b>23</b>
2.1 Utilização de sensoriamento remoto no estudo da cobertura florestal .....	23
2.2 Estimativa de variáveis biofísicas via sensoriamento remoto.....	30
2.3 Influência da geometria de iluminação na caracterização espectral de dosséis florestais e na estimativa de variáveis biofísicas .....	34
<b>3 MATERIAL E MÉTODOS.....</b>	<b>41</b>
3.1 Área de estudo.....	41
3.1.1 Geomorfologia.....	41
3.1.2 Clima.....	42
3.1.3 Solo .....	42
3.1.4 Vegetação.....	43
3.2 Sensor Hyperion.....	43
3.3 Metodologia .....	46
3.3.1 Imagem Hyperion.....	47
3.3.2 Pré-processamento dos dados Hyperion .....	49
3.3.2.1 Correção do <i>striping</i> .....	49
3.3.2.2 Correção atmosférica .....	51
3.3.2.3 Correção de ruídos na imagem.....	53
3.3.2.4 Correção geométrica .....	55
3.3.3 Simulação de dados dos sensores HRV e TM.....	55
3.3.4 Dados topográficos .....	57
3.3.5 Dados cadastrais .....	58
3.3.6 Caracterização espectral dos dosséis das espécies do gênero <i>Eucalyptus</i> spp.....	60
3.3.6.1 Componentes Principais.....	61
3.3.6.2 Considerando a iluminação .....	63
3.3.6.3 Desconsiderando a iluminação .....	65
3.3.7 Relação entre dados hiperespectrais e o volume de madeira .....	66
3.3.7.1 Cálculo dos Índices de Vegetação .....	66
3.3.7.2 Relação entre dados hiperespectrais e volume de madeira desconsiderando a iluminação.....	69
3.3.7.3 Relação entre dados hiperespectrais e o volume de madeira considerando a iluminação.....	72
<b>4 RESULTADOS.....</b>	<b>75</b>
4.1 Cálculo do fator de iluminação e definição de classes de iluminação.....	75
4.2 Caracterização espectral dos dosséis das espécies do gênero <i>Eucalyptus</i> .....	76
4.2.1 Imagens geradas pela análise das componentes principais.....	76
4.2.2 Seleção das amostras de treinamento para o processo de classificação .....	77

4.2.2.1 Sensor Hyperion .....	77
4.2.2.2 Sensor TM.....	84
4.2.2.3 Sensor HRV.....	89
4.2.3 Classificação e validação dos resultados .....	92
4.2.3.1 Considerando a iluminação .....	92
4.2.3.2 Desconsiderando a iluminação .....	97
4.3 Relação entre dados hiperespectrais e o volume de madeira .....	101
4.3.1 Estimativa do volume de madeira desconsiderando a iluminação .....	101
4.3.2 Estimativa do volume de madeira considerando a iluminação .....	103
4.3.2.1 Classe iluminado.....	103
4.3.2.2 Classe Plano .....	104
4.3.2.3 Classe Pouco Iluminado .....	105
4.3.2.4 Classe Escuro.....	106
<b>5 CONCLUSÕES .....</b>	<b>111</b>
<b>6 REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>113</b>

## LISTA DE FIGURAS

2.1 - Comprimentos de onda selecionados pela análise discriminante linear.....	29
3.1 - Localização da área de estudo. Legenda: limites municipais. ....	41
3.2 - Satélite EO-1.....	44
3.4 – Localização da cena Hyperion na região de Capão Bonito (à esquerda) e à direita o recorte para a área de estudo, composição colorida R (762,60 nm) G (660,85 nm) B (569,27 nm).....	48
3.5 - Presença de <i>striping</i> nas bandas referentes aos comprimentos de onda de 467 e 518 nm, respectivamente.....	50
3.6 – Correção do <i>striping</i> nas bandas referentes aos comprimentos de onda de 467 e 518 nm, respectivamente.....	51
3.7 – Espectro de um pixel de vegetação antes e depois da correção atmosférica. ....	53
3.8 - Espectro de um pixel de vegetação antes e depois do EFFORT. Dentro do retângulo está a região espectral submetida ao polimento.....	54
3.9 - Espectro de um pixel de vegetação antes e depois do MNF nas regiões de 1426 a 1810 nm e 1941 a 2395 nm. ....	55
3.10 – Funções-filtro para os sensores TM 5 e HRV 5. Onde: IVP = Infravermelho Próximo, IVM = Infravermelho Médio. ....	56
3.11 – Produtos SRTM: Declividade e Orientação das Vertentes .....	57
3.12 – Exemplo de vetores dos talhões com as tabelas associadas inseridos no banco de dados. ....	59
3.13 – Esquema de medição das árvores dentro de uma parcela. As setas mostram o sentido de caminhamento para cada linha.....	59
3.14 – Localização dos 88 talhões selecionados para geração do modelo. ....	70
3.15 – Polígonos referentes aos 88 talhões recortados para as classe de iluminação Iluminado (vermelho), Plano (verde), Pouco Iluminado (magenta) e Escuro (amarelo). ....	73
4.1 – Classes de iluminação referentes à imagem de 2003.....	76
4.2 – Primeiros dois fatores referentes às componentes principais 1 e 2 para as espécies de <i>Eucalyptus</i> spp. nas quatro classes de iluminação (IL=iluminado, PL=plano, PIL=pouco iluminado, ESC=escuro), originadas da imagem Hyperion.....	78
4.3 – Primeiros dois fatores referentes às componentes principais 1 e 2 (PC1 e 2) das espécies de <i>Eucalyptus</i> spp. separadas por idade para a imagem Hyperion. ....	79
4.4 – Primeiros dois fatores referentes às componentes principais 1 e 2 (PC1 e 2) para as cinco espécies de <i>Eucalyptus</i> spp. e nas classes de iluminação selecionadas (IL=iluminados; ESC=escuros) para a imagem Hyperion. ....	80
4.5 – Fotografias da linha de plantio e da copa das árvores: espécie 3 com 3 anos de idade (acima) e espécie 6 com 7 anos de idade (abaixo). ....	82
4.6 – Comparação entre os espectros médios para as espécies nas quatro classes de iluminação (acima) e os espectros para as classes de iluminação selecionadas, para a imagem Hyperion.....	83

4.7 – Primeiros dois fatores referentes às componentes principais 1 e 2 para as espécies de <i>Eucalyptus</i> spp. as quatro classes de iluminação (IL=iluminado, PL=plano, PIL=pouco iluminado, ESC=escuro) originadas da imagem TM.....	85
4.8 - Primeiros dois fatores referentes às componentes principais 1 e 2 das espécies de <i>Eucalyptus</i> spp. separadas por idade para a imagem TM. ....	86
4.9 – Primeiros dois fatores referentes às componentes principais 1 e 2 das espécies de <i>Eucalyptus</i> spp. selecionadas e nas classes de iluminação selecionadas (IL=iluminados; ESC=escuros) para a imagem TM. ....	87
4.10 – Comparação entre os espectros médios para as espécies nas quatro classes de iluminação e os espectros para as classes de iluminação selecionadas, para a imagem TM. ....	88
4.11 – Primeiros dois fatores referentes às componentes principais 1 e 2 para as espécies de <i>Eucalyptus</i> spp. nas quatro classes de iluminação (IL=iluminado, PL=plano, PIL=pouco iluminado, ESC=escuro) originadas da imagem HRV.....	89
4.12 – Primeiros dois fatores referentes às componentes principais 1 e 2 das espécies de <i>Eucalyptus</i> spp. separadas por idade para a imagem HRV. ....	90
4.13 - Primeiros dois fatores referentes às componentes principais 1 e 2 das espécies de <i>Eucalyptus</i> spp. selecionadas e nas classes de iluminação selecionadas (IL=iluminados; ESC=escuros) para a imagem HRV.....	91
4.14 - Comparação entre os espectros médios para as espécies nas quatro classes de iluminação e os espectros para as classes de iluminação selecionadas, para a imagem HRV.....	92
4.15 – Resultado da classificação para os sensores Hyperion (a), TM (b) e HRV (c) e a verdade de campo (d).....	93
4.16 – Resultado da classificação para os sensores Hyperion (a), TM (b) e HRV (c) e a verdade de campo (d), desconsiderando a iluminação. ....	98
4.17– Volume de madeira calculado e volume observado para os dados do sensor Hyperion.....	102
4.18 - Volume de madeira calculado e volume observado para os dados do sensor Hyperion, utilizando as amostras iluminadas.....	104
4.19 - Volume de madeira calculado e volume observado para os dados do sensor Hyperion, utilizando as amostras planas.....	105
4.20 - Volume de madeira calculado e volume observado para os dados do sensor Hyperion, utilizando as amostras pouco iluminadas. ....	106
4.21 - Volume de madeira calculado e volume observado para os dados do sensor Hyperion, utilizando as amostras escuras .....	107

## LISTA DE TABELAS

3.1 – Bandas calibradas e não calibradas do sensor Hyperion .....	45
3.2 – Características da Imagem Hyperion.....	48
3.3 – Variáveis de entrada selecionadas para o aplicativo FLAASH.....	52
3.4 – Exemplo de organização dos dados coletados nos talhões selecionados para a geração do modelo. ....	71
4.1 - Autovetores gerados pela análise de componente principal para a imagem TM..	77
4.2 - Autovetores gerados pela análise de componente principal para a imagem HRV. .....	77
4.3 – Valor de Kappa para cada espécie e em cada sensor, considerando a iluminação. .....	94
4.4 – Matriz de confusão para a imagem Hyperion considerando a iluminação, em pixels. ....	96
4.5 - Matriz de confusão para a imagem TM considerando a iluminação, em pixels..	96
4.6 - Matriz de confusão para a imagem HRV considerando a iluminação, em pixels.	97
4.7 - Valor de Kappa para cada espécie e em cada sensor, desconsiderando a iluminação. ....	99
4.8 - Matriz de confusão para a imagem Hyperion desconsiderando a iluminação, em pixels. ....	99
4.9– Matriz de confusão para a imagem TM desconsiderando a iluminação, em pixels. .....	100
4.10 - Matriz de confusão para a imagem HRV desconsiderando a iluminação, em pixels. ....	100



## 1 INTRODUÇÃO

O setor florestal brasileiro, responsável pela produção sempre crescente de bens oriundos de florestas plantadas, conta com cerca de 5.000.000 de hectares plantados com espécies exóticas (SBS, 2001), distribuídos em órgãos públicos e empresas privadas. Esses reflorestamentos geram os mais diversos produtos como celulose e papel, madeira para construção civil, carvão para o abastecimento da indústria siderúrgica, entre outros subprodutos.

A demanda crescente por produtos florestais fez com que as empresas do setor investissem pesadamente em pesquisas voltadas ao melhoramento genético, definição de tratamentos silviculturais como, adubação, plantio em diferentes espaçamentos e no desenvolvimento de bancos de dados (georreferenciados ou não) que auxiliam o processo de tomada de decisão no âmbito da produção florestal. Atualmente o grau de complexidade das informações necessárias para a otimização desse processo de decisão tornou-se tão grande que são comuns esforços na busca de alternativas. Dentre essas alternativas sempre ventiladas pelos técnicos atuantes no setor, destacam-se técnicas de sensoriamento remoto e de geoprocessamento.

A aplicação dessas técnicas no estudo e no monitoramento de plantios florestais tem, até o momento, oferecido poucas alternativas para as empresas efetuarem a atualização cadastral de seus plantios e a programação das atividades a serem empregadas corretamente na administração desses mesmos plantios. Os motivos que explicam essa ainda tímida contribuição talvez residam no fato de que existe forte sinergismo entre as variáveis florestais, aliado à inerente ambigüidade dos dados gerados por sensores remotos. Essa comunhão de fatores resulta em elevados graus de incerteza que comprometem o desempenho e a credibilidade das informações geradas.

Outro fator importante e que exerce influência nos resultados da aplicação das técnicas de sensoriamento remoto sobre estudos e/ou avaliação da cobertura florestal, refere-se

ao relevo. Dadas as grandes extensões territoriais ocupadas por plantios florestais comerciais, por exemplo, é esperado que estes ocupem terreno com relevo diferenciado. Essa variação de relevo implicará então em diferenças nas quantidades de radiação eletromagnética recebida pelos plantios para um mesmo posicionamento solar. Como conseqüência, espera-se que um sensor remotamente situado registre diferenças na radiância refletida por plantios florestais, mesmo que estes sejam compostos por indivíduos de mesmas espécie e idade, cultivados em um mesmo espaçamento e submetidos a idênticos tratamentos culturais. Esse fato pode ser explicado pelas características anisotrópicas da cobertura vegetal, as quais foram apontadas por Liesenberg et al. (2007), Pocewicz et al. (2007), Steininger (2000), dentre outros autores.

Apesar dessas esperadas limitações, a disponibilidade de dados hiperespectrais aerotransportados e orbitais trouxe expectativas positivas ao setor florestal. Os dados coletados em bandas estreitas e de forma contígua no espectro eletromagnético podem permitir, por exemplo, a identificação de diferenças estruturais e bioquímicas decorrentes da adoção de tratos culturais diferenciados, auxiliando assim no processo de tomada de decisão no cotidiano de empresas florestais. Esse processo de decisão é totalmente fundamentado em duas vertentes da administração florestal, quais sejam, o inventário e o manejo florestal, e estes dependem quase exclusivamente de trabalhos realizados em campo.

Atualmente os dados oriundos de inventário florestal são armazenados em bancos de dados geográficos, o que tem sistematizado as informações sobre povoamentos florestais (BOLFE et al., 2003). Tais bancos de dados são alimentados por produtos de sensoriamento remoto, permitindo prioritariamente a elaboração de mapas temáticos oriundos de atividades de manejo como desbastes, corte raso, manutenção de aceiros etc. A variável volume de madeira é tradicionalmente obtida em parcelas lançadas no campo e, por meio de equações alométricas, é extrapolada para toda a área plantada. Alguns estudos foram feitos com o objetivo de estimar o volume de madeira utilizando dados de sensores remotos multiespectrais alcançaram diferentes graus de sucesso, na maioria das vezes com erros superiores àqueles alcançados pelo método tradicional.

O presente trabalho teve como objetivo principal avaliar o potencial da aplicação de dados hiperespectrais na caracterização espectral de plantações do gênero *Eucalyptus* spp., visando o processo de classificação e de espacialização do volume de madeira, levando em consideração a influência da geometria de iluminação ocasionada pelo relevo.

De forma específica, o trabalho teve os seguintes objetivos:

1. Identificar a distribuição espacial das espécies presentes na área de estudo por meio do processo de classificação;
2. Verificar a influência da geometria de iluminação nesse processo;
3. Comparar os resultados da classificação com a classificação obtida pelos dados simulados para os sensores TM do satélite Landsat e HRV do SPOT;
4. Testar a aplicabilidade de dados hiperespectrais na espacialização do volume de madeira;
5. Verificar se a geometria de iluminação exerce influência na espacialização dessa variável biofísica.



## **2 FUNDAMENTAÇÃO TEÓRICA**

### **2.1 Utilização de sensoriamento remoto no estudo da cobertura florestal**

Desde que as primeiras imagens dos satélites da série Landsat tornaram-se disponíveis à comunidade científica, muitos estudos têm demonstrado a aplicabilidade das informações espectrais para discriminar diferentes fisionomias vegetais. Juntamente com a capacidade de análise multiespectral vieram as limitações da utilização desses dados. Cientistas descobriram que alguns objetos da superfície da Terra e em faixas espectrais específicas refletem a energia eletromagnética de maneira similar, sendo registradas também similarmente quando captadas por um sensor remoto multiespectral (CARVALHO et al., 2004), o que caracteriza a já conhecida ambigüidade dos produtos de sensoriamento remoto.

A identificação de espécies florestais utilizando o sensoriamento remoto, na maioria das vezes, é feita por meio de um processo de classificação, seja ele supervisionado ou não. Na prática, muitos fatores podem limitar a acurácia da classificação da cobertura vegetal como as resoluções espacial e espectral do sensor utilizado, a variabilidade espectral das folhas que compõem os dosséis analisados, as reflectâncias adicionais à folhagem como, por exemplo, o subbosque, a estrutura da vegetação, condições de iluminação e o aspecto da copa (GONG et al., 1997; GOODWIN et al., 2005).

As resoluções espacial e espectral possuem forte influência na exatidão dos processos de classificação de imagens digitais. Sensores foram desenvolvidos apresentando aperfeiçoamentos significativos nos domínios radiométrico, espacial e espectral bem como na relação sinal-ruído. A alta resolução espacial pode facilitar a localização e o delineamento de copas individuais enquanto que a alta resolução espectral pode facilitar a identificação de feições relacionadas às propriedades biofísicas e bioquímicas (GROSS e SCOTT, 1998).

A variabilidade das características espectrais de espécies individuais pode afetar o desempenho de processos voltados à identificação de espécies utilizando sensoriamento

remoto. Seria ideal que essa variabilidade interna a um grupo de indivíduos de uma mesma espécie fosse menor do que a variabilidade entre grupos de espécies diferentes (GOODWIN et al., 2005). Porém, a reflectância das folhas pode variar muito na copa de uma mesma árvore (COCHRANE, 2000). Para Ponzoni (2001), a reflectância das folhas individuais dependem da sua composição química, morfologia, fisiologia e umidade interna. Mas quando se trata das propriedades espectrais da copa ou de conjuntos de copas (dosséis), outros fatores as explicam, como as geometrias de iluminação e de visada, propriedades espectrais dos elementos da vegetação (folhas, solo, troncos etc), o índice de área foliar e a distribuição angular das folhas.

Poucos estudos foram realizados com sensores de resolução espacial média, como TM/Landsat e HRV, com o objetivo de identificar espécies individuais. A maior parte dos trabalhos utilizou o processo de classificação para separar apenas diferentes fisionomias vegetais.

Carvalho et al. (2004) utilizaram dados do sensor TM/Landsat para o mapeamento da floresta atlântica semidecidual. Foram avaliadas as classes floresta e não-floresta e foram analisados sete conjuntos de atributos como dados multitemporais, série temporal do Índice de Vegetação da Diferença Normalizada (IVDN) ou *Normalized Difference Vegetation Index* (NDVI), topografia, textura espacial, textura temporal entre outras. Entre as classes não-floresta havia plantios de café e de *Eucalyptus spp.* Foi feita uma classificação utilizando para isso o classificador máxima verossimilhança, rede neural e árvore de decisão. As exatidões nas classificações ficaram entre 34,5 a 51,3 % para a máxima verossimilhança, e 19,0 a 45,2 % para a rede neural. As informações temporais do NDVI foram mais importantes do que a textura da imagem e a topografia para discriminar floresta atlântica semidecídua.

Bolfe et al. (2003) realizaram levantamento de plantios florestais utilizando imagens TM/Landsat e técnicas de classificação digital no Rio Grande do Sul. O método de classificação escolhido foi supervisionado e o classificador selecionado foi o de máxima verossimilhança. Os autores estudaram três classes de vegetação: florestas de *Pinus sp.*,

de *Eucalyptus* sp. e florestas nativas em vários estágios sucessionais. A exatidão global da classificação ficou em 85,23 % e Kappa<sup>1</sup> de 84,9 %.

Evidentemente, existem na literatura muitos outros exemplos de trabalhos voltados à identificação fitofisionômica que exploraram dados de sensores remotos dotados de diferentes características espectrais, radiométricas, temporais e espaciais. Estes trabalhos são normalmente designados como trabalhos de cunho qualitativo, nos quais se busca representar cartograficamente a distribuição espacial de diferentes fisionomias vegetais.

O trabalho de Foody e Cutler (2002) tentou quantificar a biodiversidade de uma floresta tropical utilizando dados TM/Landsat por meio de dois tipos de rede neurais. Primeiramente, uma rede neural padrão “feedforward” foi utilizada para estimar a riqueza de espécies e em seguida a rede neural Kohonen foi utilizada para mapear as espécies. Um trabalho de campo foi realizado para identificar e quantificar as espécies florestais. Pela combinação dos resultados dessas duas análises, um mapa foi confeccionado para demonstrar a variação espacial do número de espécies. O R<sup>2</sup> encontrado entre o número de espécies observadas no campo e o número de espécies estimado utilizando dados TM/Landsat foi de 0,4768.

A utilização de dados de sensoriamento remoto hiperespectral orbital para identificação florística está em processo inicial de investigação, uma vez que o primeiro sensor desse tipo foi lançado em 2000. Estudos anteriores foram realizados com sensores em níveis de campo e aéreo, o que não permitia uma repetitividade freqüente e constante de coleta de dados.

Dados de sensoriamento remoto hiperespectral constituem aumento no potencial de discriminação de espécies vegetais quando comparados com sensores remotos multiespectrais. Para algumas aplicações, bandas estreitas localizadas em porções específicas do espectro eletromagnético podem aumentar a exatidão da identificação de

---

<sup>1</sup> O índice estatístico kappa foi descrito para estabelecer o grau de concordância entre dois avaliadores ao classificarem dois objetos distintos. É freqüentemente utilizado para avaliar a confiabilidade de determinada escala de categorias através da concordância entre esses observadores.

espécies para vários tipos de vegetação e culturas agrícolas (THENKABAIL et al., 2004).

Alguns trabalhos foram realizados com o intuito de identificar espécies em florestas tropicais. Entre eles está o estudo feito por Clark et al. (2005), no qual foram coletados espectros das copas das árvores emergentes em uma floresta, utilizando o sensor aerotransportado hiperespectral HYDICE (*Hyperspectral Digital Imagery Collection Experiment*) e dados espectrais obtidos em laboratório. Foram analisadas as reflectâncias nas escalas foliar (laboratório), de copa e de pixel (aerotransportado) e foram utilizados três classificadores com o objetivo de identificar as espécies: análise discriminante linear, máxima verossimilhança e *Spectral Angle Mapper* (SAM), os quais foram aplicados em uma combinação de bandas que foram selecionadas utilizando a estratégia *stepwise*. As bandas na região do visível foram importantes no processo de classificação para todas as escalas. Já as bandas do infravermelho próximo foram importantes nas escalas de pixel e de dossel. A análise discriminante linear utilizada em nível foliar obteve uma exatidão na classificação de 100% utilizando 40 bandas. Para o nível de copa, a exatidão de classificação foi de 92,1% e para o nível de pixel, a exatidão na classificação foi de 86% utilizando 40 bandas.

Outro trabalho foi realizado por Schmidt e Skidmore (2003) para diferenciar 27 espécies utilizando dados hiperespectrais obtidos no campo. Primeiramente, foi feito um teste para detectar se a variabilidade espectral entre indivíduos da mesma espécie era menor do que a variabilidade espectral entre indivíduos de espécies diferentes, utilizando o teste-U Mann Whitney. Depois foi avaliado se a diferença estatística entre os espectros das 27 espécies era realçada quando o método de remoção de contínuo (técnica de normalização dos dados) foi utilizado para identificar bandas de absorção espectral nas espécies. Depois que as diferenças estatísticas foram encontradas, foi determinada a distância no espaçamento espectral entre as classes (espécies) utilizando as distâncias Bhattacharyya e a Jeffries-Matusita em seis comprimentos de onda selecionados no primeiro passo. Os dados hiperespectrais tornaram possível identificar profundidades de bandas de absorção nos espectros das espécies bem como diferenças na reflectância média absoluta, o que auxiliou no processo de identificação das espécies.

Há também trabalhos realizados em ambientes com menor biodiversidade. O estudo desenvolvido por Underwood et al. (2003) teve como objetivo o mapeamento de espécies exóticas utilizando imagem hiperespectral. Foi utilizado o classificador máxima verossimilhança para mapear essas espécies. Foram utilizadas razões de banda e foi feita a remoção do contínuo para a identificação de bandas de absorção de água. A identificação dessas bandas possibilitou que as espécies invasoras fossem identificadas, pois elas possuem conteúdo de água nas folhas diferente das espécies nativas. A exatidão da classificação foi de 54,9% para as bandas selecionadas pelo método de remoção do contínuo e de 58,8% para o método que utilizou a razão de bandas.

Gong et al. (1997) trabalharam com dados hiperespectrais obtidos em campo por meio do espectrômetro PSD 1000, com o objetivo de identificar seis espécies arbóreas de coníferas. Um algoritmo de rede neural (RN) foi avaliado para o propósito de identificação das espécies. Foi utilizada também a análise discriminante linear (ADL) com o mesmo propósito. Os resultados dos dois métodos foram comparados. Foram utilizados os dados hiperespectrais de reflectância de superfície em 226 bandas e dados do espectro obtido pela primeira derivada, os quais foram usados separadamente na identificação das espécies. A discriminação das espécies arbóreas com dados coletados em seis áreas de estudo foi testada em sete experimentos. Entre os experimentos, foi testada a influência do sombreamento (geometria de iluminação) e do background (solo) na caracterização espectral das espécies. Para isso, foram coletados espectros de cada espécie localizada em áreas de estudo diferentes, gerando classes diferentes. Essas classes foram testadas utilizando RN e ADL. Se a exatidão da classificação fosse de 0% indicaria que os diferentes tipos de solo não estariam exercendo influência na caracterização espectral daquela espécie. O mesmo foi feito para espectros coletados para cada espécie localizada em partes sombreadas e iluminadas da imagem. Os resultados indicaram que, tanto o tipo de solo quanto a geometria de iluminação, influenciaram na caracterização espectral das espécies e que a seleção de algumas bandas pode resultar em uma melhor exatidão no processo de identificação das espécies do que a utilização de todas as bandas espectrais.

Todos esses estudos foram realizados para identificar espécies de gêneros diferentes. O desafio maior está na identificação de espécies do mesmo gênero, onde as diferenças espectrais entre as espécies se apresentam de forma mais sutil, tornando o processo de identificação florística muito mais complexo.

Galvão et al. (2005) avaliaram a aplicação de dados hiperespectrais do sensor Hyperion para discriminar cinco espécies de cana-de-açúcar. Os autores utilizaram a análise discriminante múltipla e as variáveis selecionadas foram: valores de reflectância das bandas de absorção de clorofila, água nas folhas, lignina-celulose para gerar índices espectrais sensíveis a esses componentes. Utilizaram também profundidade de bandas em: 671 nm (clorofila), 983 e 1205 nm (água nas folhas), 2103 e 2304 (lignina e celulose), as quais foram calculadas pixel a pixel pelo método de remoção do contínuo. Após a análise do espectro das cinco variedades de cana, algumas bandas também foram selecionadas em comprimentos de onda estratégicos, para a diferenciação das espécies. As profundidades dessas bandas, valores de reflectâncias das bandas selecionadas e razão de bandas entraram como variáveis em uma função discriminante. Depois foram coletadas amostras espectrais as quais foram utilizadas para validar a função discriminante gerada. A exatidão da identificação foi de 87,5%.

Estudos preliminares identificando espécies de *Eucalyptus* utilizando sensoriamento remoto hiperespectral foram realizados por Goodwin et al. (2005) e Datt (2000). Os primeiros autores utilizaram dados hiperespectrais provenientes de sensor aerotransportado (CASI-2) com o objetivo de identificar as espécies *E. acmenoides*, *E. pilularis*, *E. saligna*, *E. paniculata*, *E. sideroxylon* e *E. deanei*. Os autores não conseguiram discriminar as espécies com os dados do sensor estudado, pois o mesmo possuía apenas 10 bandas estreitas posicionadas na região do visível e infravermelho próximo (450 a 850 nm). Essa região espectral permitiu inferir somente sobre pigmentos fotossintetizantes, mas foi insuficiente para o objetivo do trabalho.

Datt (2000) realizou medições de laboratório do Fator de Reflectância Bidirecional (FRB) de folhas de seis espécies de *Eucalyptus* (*E. haemastoma*, *E. piperita*, *E. gummifera*, *E. fastigata*, *E. pilularis* e *E. saligna*). Uma análise discriminante linear foi

utilizada para individualizar as espécies. Como resultado, o autor conseguiu identificar as 6 espécies de *Eucalyptus* e algumas bandas foram indicadas como importantes nesse processo: 500, 540, 550, 590 e 680 nm (relacionadas com os conteúdos de clorofila); 1170, 1270, 1280, 1720e 2200 nm ( Figura 2.1). Esse trabalho comprovou então a possibilidade de discriminar espécies de *Eucalyptus* utilizando dados de sensoriamento hiperespectral, ao menos para a escala de trabalho adotada.

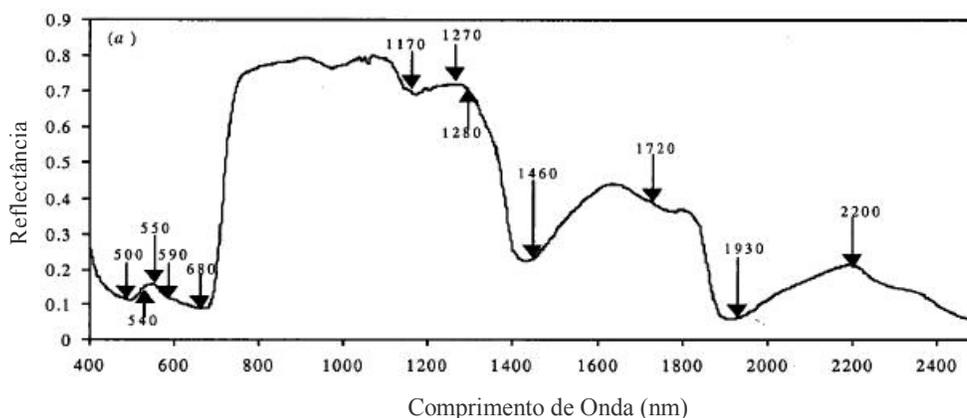


Figura 2.1 - Comprimentos de onda selecionados pela análise discriminante linear.  
Fonte: Datt (2000).

Há também o trabalho realizado por Coops e White (2003) onde os autores tentaram distinguir três espécies em floresta tropical e três espécies do gênero *Eucalyptus* (*E. saligna*, *E. pilularis* e *E. paniculata*) utilizando a reflectância média das copas com dados do sensor *Compact Airborne Spectrographic Imager 2* (CASI-2). Os comprimentos de onda de 720 nm e 740 nm ofereceram maior capacidade de discriminação dessas espécies. Os resultados indicaram que os indivíduos do gênero *Eucalyptus* não foram facilmente discriminados, principalmente pela complexidade das florestas de *Eucalyptus*, expressa principalmente pela composição estrutural dessas árvores, as quais possuem folhas posicionadas verticalmente e com uma grande variação em seus estágios de maturação em um mesmo galho, lhes conferido diferentes características espectrais.

## 2.2 Estimativa de variáveis biofísicas via sensoriamento remoto

A obtenção de informações sobre a estrutura florestal é feita por meio de expedições de campo, onde são lançadas parcelas e medidos os diâmetros das árvores à altura do peito (DAP), a altura e o número de árvores na parcela, além de outros parâmetros dendrométricos. Utilizando esses dados são estimadas outras variáveis como área basal, volume de madeira, biomassa e os valores encontrados na parcela são extrapolados para a área como um todo. Os procedimentos aplicados nesses levantamentos constituem uma das etapas do chamado *inventário florestal*.

A crescente necessidade de informação a respeito do crescimento das florestas trouxe novas metodologias para complementar o inventário florestal tradicional realizado em campo. Essas técnicas visam a predição de variáveis biofísicas utilizando as medidas feitas em campo aliadas ao sensoriamento remoto digital, possibilitando atualizações dos dados bem como a validação de modelos (COOPS e WHITE, 2003).

Diferente da classificação, a qual é tipicamente direcionada pelo entendimento estatístico da resposta dos padrões espectrais, a estimativa de variáveis biofísicas é feita geralmente por modelos empíricos e semiempíricos. Parâmetros como fechamento de copa, área basal ou volume de madeira são introduzidos como variáveis dependentes e podem ser preditos ou estimados utilizando dados contidos em uma imagem gerada por um sensor remotamente situado (FRANKLIN, 2001).

Para este mesmo autor, é necessário então estabelecer um número de parcelas para observações de campo, realizar a coleta de dados biofísicos nessas parcelas, adquirir imagem de sensor remoto com a data de passagem na área de interesse próxima à data da expedição de campo, localizar as parcelas na imagem, extrair dados das imagens como reflectância de superfície, desenvolver modelo para relacionar os dados de campo e os dados espectrais e finalmente utilizar esse modelo para espacializar os parâmetros florestais para todos os pixels ocupados pelo padrão espectral florestal na imagem.

Diversos estudos foram realizados com sensores remotos que operam em bandas de faixas largas, como o TM/Landsat por exemplo. Dentre eles, está o trabalho realizado

por Thenkabail et al. (2003). Os autores utilizaram imagens do sensor IKONOS e ETM+/Landsat e correlacionaram os valores de reflectância e índices de vegetação obtidos das imagens com dados coletados em campo em uma floresta mista da África Central. A maior resolução espacial do sensor IKONOS (pixel de 4 m) não resultou em melhores resultados quando comparados com o sensor ETM+/Landsat (pixel de 30 m). O  $R^2$  encontrado para as relações estabelecidas com dados IKONOS foi de 0,34. As melhores relações foram obtidas pelas bandas do infravermelho médio do sensor ETM+/Landsat (bandas 5 e 7) e o  $R^2$  alcançou valor de 0,69 para a estimativa do volume de madeira. Portanto, a melhoria na resolução espacial não apresentou melhoria nos resultados alcançados.

Outro estudo foi realizado com dados do sensor IKONOS-2 para testar a melhoria na capacidade das imagens de 1m de resolução espacial (pancromática) na estimativa de variáveis florestais como idade, altura total, DAP e área basal. A área de estudo estava localizada na Bélgica em uma formação florestal dominada basicamente por três espécies: *Quercus* sp.; *Fagus sylvatica* L. e *Picea abies* (L.) Karst. Foram analisadas três texturas: contraste, variância e correlação as quais foram calculadas para a imagem IKONOS-2. As feições relativas à textura entraram em um modelo como variáveis independentes e as variáveis florestais como dependentes. Foram separadas 29 amostras para validação. Os coeficientes de determinação  $R^2$  foram de 0,35 para área basal; 0,76 para a altura das árvores e de 0,82 para a circunferência e idade utilizando as feições correlação e contraste. Os erros foram de 10% para a altura, 15% para a DAP, 16% para área basal e 18% para idade (KAYITAKIRE et al., 2006).

Outro trabalho foi feito por Foody et al. (2003) utilizando dados TM/Landsat para estimar biomassa em três locais: Brasil, Malásia e Tailândia, onde foram coletados dados de campo. Foram desenvolvidos três tipos de relações preditivas baseadas em índices de vegetação, regressão múltipla e rede neural, as quais foram calculadas separadamente para cada local avaliado. O índice de vegetação que apresentou maior correlação com a biomassa foi o NDVI e os resultados foram diferentes para cada local. O melhor resultado encontrado foi  $R = 0,71$  a 99% de confiança utilizando as redes neurais.

Lu et al. (2004) exploraram a relação entre variáveis biofísicas florestais e dados do sensor TM/Landsat em três locais da região amazônica. As seis bandas deste sensor referentes ao espectro óptico foram analisadas, assim como índices de vegetação, componentes principais e transformação *tasseled cap*. Foram feitas coletas de dados no campo onde foram medidas a altura das árvores e o DAP e a partir desses dados foram calculadas a biomassa e a área basal. Foi utilizado o coeficiente de correlação de Pearson para interpretar as relações entre os dados biofísicos e os dados do sensor TM/Landsat. O estudo concluiu que a banda 5, a componente principal 1, a transformação *tasseled cap* e o albedo (soma da reflectância das 6 bandas) foram as variáveis mais correlacionadas com os dados biofísicos. O Índice de Vegetação Atmosféricamente Resistente (ARVI), Índice de Vegetação da atmosfera e do solo (ASVI) e o Índice de Vegetação da Diferença Normalizada (NDVI) não apresentaram boas correlações com os dados biofísicos, ao contrário do que ocorreu com os índices que incluíram em seus cálculos os dados da banda 5.

O estudo de Mäkelä e Pekkarinen (2004) também utilizou dados do sensor TM/Landsat e relacionou-os com volume de madeira em uma floresta na Finlândia. Foi utilizado um estimador não paramétrico kNN (*k-nearestneighbour*). Os talhões foram delineados e deles foram extraídos valores como a média e o desvio padrão. Também foram separados os pixels que estavam nas bordas dos talhões e os pixels localizados no centro do talhão. O menor erro encontrado (RSME) para o volume de madeira estimado foi de 48% quando foi utilizada a média dos pixels localizados no centro do talhão.

Outro trabalho foi desenvolvido por Hall et al. (2006), no Canadá, utilizando o BioSTRUCT, sendo o volume e a biomassa estimados a partir da altura das árvores e do fechamento de copa medidos em campo. As duas últimas variáveis foram modeladas utilizando dados ETM+/Landsat e dados de campo e esses atributos modelados serviram como dados de entrada para estimativas da biomassa e do volume de madeira. As relações obtidas mediante os dados da imagem *altura das árvores*, gerada pelo modelo, obteve o  $R^2$  ajustado de 0,65 utilizando as bandas 3, 4 e 5 e a imagem *fechamento de copa* obteve  $R^2$  de 0,57 utilizando as bandas 3,4 e 7. O valor de  $R^2$  para biomassa

estimada ficou em 0,65 e para o volume em 0,69. O erro calculado a partir das amostras de validação ficou em 37,6 Ton/ha para a biomassa e de 70,3 m<sup>3</sup>/ha para o volume.

Mais recentemente, dados hiperespectrais começaram a ser utilizados para estimar variáveis biofísicas de áreas florestais. Um deles foi desenvolvido por Gong et al. (1995), no qual foram utilizados dados do sensor aerotransportado CASI (*Compact Airborne Spectrographic Imager*) para estimar o IAF (Índice de Área Foliar) em uma floresta de coníferas. Três técnicas foram utilizadas: regressão univariada e regressão múltipla. A regressão linear múltipla foi o método que apresentou os maiores valores de R<sup>2</sup> (0,80). Estudos semelhantes foram realizados por Fernandes et al. (2002) e Hu et al. (2000) com dados do CASI utilizando a inversão de modelos de reflectância para a estimativa do IAF em uma floresta com várias espécies de coníferas e outra somente com espécies pertencentes ao gênero *Pinus*. Os resultados obtidos por esses autores apresentaram R<sup>2</sup> variando entre 0,51 a 0,86 e de 0,16 a 0,67, respectivamente.

Já o trabalho de Lucas et al. (2000) utilizam dados do mesmo sensor CASI para estimar IAF, porém foram utilizados o ponto de inflexão da borda vermelha (REIP) e a metodologia explorada foi a análise de regressão bivariada, com a correlação identificada de 0,94 entre as variáveis.

O estudo desenvolvido por Schlerf et al. (2005) utilizou o sensor aerotransportado HyMap e dados de campo para estimar o IAF. Foram calculados índices de vegetação a partir de bandas largas (simuladas) como Razão Simples (SR), Índice de Vegetação da Diferença Normalizada (NDVI), entre outros e índices de banda estreita como Índice de Vegetação da Razão (RVI) e Índice de Vegetação Perpendicular (PVI). Foram analisadas duas técnicas: a inversão do modelo Gaussiano e a interpolação Lagrange. O índice PVI, baseado nas bandas 1088 e 1148 nm, foi linearmente relacionado ao IAF, com R<sup>2</sup> = 0,67. Já o PVI calculado a partir das bandas 885 e 948 nm foi linearmente relacionado ao volume de madeira (R<sup>2</sup> = 0,79). Esse estudo demonstrou que para imagens hiperespectrais, modelos de regressão linear podem ser aplicados para quantificar o IAF e volume de madeira com boa acurácia. Para dados provenientes de sensores que operam em banda larga, a acurácia é geralmente mais baixa e isso pode ser

um indicativo que os dados hiperespectrais contêm mais informações relevantes para estimar variáveis biofísicas de florestas do que dados de sensores multiespectrais.

Os estudos realizados até então não avaliaram a influência da geometria de iluminação na estimativa de variáveis biofísicas por meio de dados de sensores remotos.

### **2.3 Influência da geometria de iluminação na caracterização espectral de dosséis florestais e na estimativa de variáveis biofísicas**

Antes de discutir como a geometria de iluminação afeta a caracterização espectral das espécies florestais, influenciando assim a identificação de espécies e a relação entre a reflectância e a estimativa de variáveis biofísicas, convém descrever brevemente os fatores que interferem na reflectância de uma folha isolada e de um dossel florestal.

Considerando uma folha individual, sua reflectância é controlada principalmente por: 1) propriedades bioquímicas foliares (água nas folhas, pigmentos fotossintetizantes, carboidratos estruturais), os quais estão associados a comprimentos de onda específicos, na forma de bandas de absorção, e 2) morfologia da folha (espessura da parede celular, espaços de ar e cera cuticular) os quais afetam o espalhamento da radiação eletromagnética (ASNER, 1998). Na região do visível, o principal fator que predomina na reflectância das folhas é a quantidade e o tipo de pigmentos fotossintetizantes presentes nas folhas. Na região do infravermelho próximo, a estrutura interna das folhas (como os espaços de ar) é quem controla a reflectância. Já na região do infravermelho médio, as moléculas d'água presentes no interior das folhas controlam a reflectância foliar. A absorção da radiação causada por essas moléculas pode mascarar outras feições de absorção produzidas pelos constituintes bioquímicos, como a lignina e a celulose (CLARK et al., 2005).

Quando a reflectância de um dossel vegetal é estudada, os fatores que afetam sua reflectância em nível foliar são somados ao arranjo das folhas, à arquitetura do dossel e também a geometria de iluminação e visada (PONZONI e SHIMABUKURO, 2007). Dois parâmetros são freqüentemente considerados como descritores da arquitetura de um dossel: o IAF (Índice de Área Foliar) e a DAF (Distribuição Angular de Folhas). Evidentemente que estes descritores podem não ser os mais representativos para

qualquer tipo de dossel. Para o caso de dosséis de porte florestal, o ângulo de inserção de galhos, a forma das copas, as projeções verticais das copas, o espaçamento entre indivíduos, além de outros, podem ser também considerados como descritores dessa arquitetura.

O IAF é a razão entre a área total de folhas por unidade de área de superfície do solo. Esse índice é comumente utilizado para medições de crescimento e desenvolvimento vegetativo (BEST e HARLAN, 1985), sendo um importante parâmetro do dossel, necessário em modelos de previsão do crescimento de plantas e de evapotranspiração. É frequentemente relacionado à biomassa vegetal (HUETE, 1988; PONZONI, 2001). Variação nos valores de IAF pode estar relacionado a variáveis ambientais, como a fenologia, e são, então, intrinsecamente ligados ao tipo de vegetação e varia no espaço e no tempo, associados aos processos ecofisiológicos (GREGOIRE e RAFFY, 1997).

A DAF é caracterizada por uma função de densidade de distribuição  $f(\theta_L, \psi_L)$  onde  $\theta_L$  e  $\psi_L$  são ângulos de inclinação da folha e azimute da folha, respectivamente. Assim  $f(\theta_L, \psi_L) d\theta_L$  e  $d\psi_L$  é a fração de área foliar nos ângulos de inclinação  $\theta_L$  e  $\theta_L+d\theta_L$  e os ângulos azimutais  $\psi_L$  e  $\psi_L+d\psi_L$ . Na maioria dos modelos de reflectância do dossel, essa fração é assumida como sendo azimutalmente simétrica, o que parece ser uma boa aproximação para muitos tipos de vegetação. Os dosséis geralmente são descritos em seis tipos de distribuição: folhas planófilas (predominam folhas horizontais), erectófilas (predominam folhas com orientação vertical), plagiófilas (são mais freqüentes folhas oblíquas), extremófilas (folhas oblíquas são menos freqüentes), uniformes (mesma proporção de folhas em um mesmo ângulo) e esféricas (as folhas são arranjadas em vários padrões simultaneamente) e cada um apresenta um ângulo de inclinação das folhas correspondente (GOEL e STREBEL, 1984). Para os mesmo autores, mudanças na distribuição da inclinação e de ângulos azimutais da folha, podem estar correlacionadas com estresse, assim mudanças nas distribuições angulares podem ser utilizadas para quantificar esse estresse. Muitas plantas podem ainda apresentar variações na DAF em função do horário do dia em que a imagem foi adquirida (KIMES e KIRCHNER, 1983). São os chamados dosséis heliófilos.

Parâmetros biofísicos como o IAF e a DAF dominam na reflectância de dosséis densos (GARCIA-HARO e SOMMER, 2002). Porém, quando o dossel florestal é mais aberto (árvores mais espaçadas) a radiação eletromagnética pode chegar até a outros elementos da vegetação, como galhos e troncos, e atingir o solo ou outro tipo de vegetação que se encontra nas porções mais inferiores do dossel. Assim, o sinal que chegará ao sensor será uma mistura das propriedades espectrais de todos esses elementos participantes no “brilho” do dossel (GOODWIN et al., 2005).

As geometrias de iluminação e visada são parâmetros geométricos que caracterizam a bidirecionalidade da radiância medida por sensores remotos. A geometria de iluminação refere ao posicionamento do sol e a geometria de visada ao posicionamento do sensor (PONZONI e SHIMABUKURO, 2007).

Goel (1988) comenta que quando o Sol encontra-se atrás do sensor, grande proporção dos componentes da vegetação se apresentará bem iluminada em uma imagem proveniente de um sensor remoto, podendo ocultar sombra dentro do dossel ou na superfície do solo. Um dossel é composto por várias camadas de folhas com uma variedade de inclinações das mesmas (ângulos azimutais e zenitais), podendo haver sombreamento de uma folha por outra acima posicionada. Para Kimes (1983) o DAF também influencia na probabilidade de ocorrências de lacunas através do dossel, em função do zênite solar e ângulo de visada, os quais determinam se o fluxo incidente e refletido serão ou não interceptados pela vegetação.

O trabalho realizado por Breece e Holmes (1971) mostrou a forte dependência da reflectância com o ângulo de incidência e os comprimentos de onda, quando medidas espectrais de folhas (milho e soja) foram tomadas com diferentes ângulos de iluminação (0, 15, 30, 45 e 60°) e ângulos de visada no plano principal. Essas medidas permitiram constatar grande dependência da reflectância com o ângulo de iluminação e o comprimento de onda, caracterizando o espalhamento da radiação para as folhas de milho e soja como não-isotrópico ou não-Lambertiano.

Colwell (1974) descreveu como os efeitos angulares alteravam a resposta espectral de um dossel. Dependendo de como o dossel era iluminado, em quais comprimentos de

onda e sob que geometria ele era observado, a reflectância poderia variar dramaticamente. Até então, as visadas eram tomadas considerando a reflectância hemisférica e esses dados eram insuficientes para explicar a reflectância do dossel e sua variabilidade diante das mudanças intrínsecas e alterações nas condições ambientais.

Em um estudo realizado por Combal e Isaka (2002), avaliou-se a influência da topografia no fator de reflectância bidirecional (FRB) proveniente de dosséis. O FRB de dosséis apresenta uma dependência não linear com a declividade e a orientação das vertentes, mesmo em terrenos pouco montanhosos. O estudo mostrou que com o Sol posicionado em 60° em relação ao zênite, a reflectância de alvos terrestres pode ser diferente entre terrenos planos e terrenos com até 10% de declividade ou menos, indicando que a topografia deve ser considerada na caracterização espectral de alvos terrestres.

No trabalho realizado por Ferraz (2006) foi estudado o comportamento espectral de culturas agrícolas utilizando imagens adquiridas sob diferentes ângulos de visada e em diferentes horários de passagem. Foram avaliados três ângulos de visada (0°, 30° e 45°) e três horários de medição (10 horas, 12 horas e 14 horas), o que implica em diferentes ângulos de elevação solar, na resposta espectral da cultura de feijão, como também nas relações entre o índice de área foliar (IAF) e o Índice de Vegetação da Diferença Normalizada (NDVI). Foram realizadas medições no campo, com o espectrorradiômetro SPECTRON SE-590. Dos fatores de reflectância bidirecional determinados, simularam-se as bandas 3 e 4 do sensor TM/Landsat e a partir destas, foram gerados os índices de vegetação. De acordo com os resultados obtidos, concluiu-se que a variação do horário de medição não proporcionou variação significativa sobre os valores do FR nas bandas 3 e 4. Já a variação do ângulo zenital de visada influenciou significativamente, ao nível de 5 % de probabilidade, o FR nas bandas 3 e 4, para todos os dias de leitura. Quanto às relações IAF e NDVI, o modelo linear apresentou melhores ajustes, estatisticamente significativos ( $p \leq 0,05$ ).

O estudo desenvolvido por Latorre et al. (2001) avaliou os efeitos da iluminação na estimativa do fator de reflectância bidirecional utilizando dados AVIRIS (*Airborne*

*Visible/Infrared Imaging Spectrometer*). Foram usadas amostras de floresta ripária e solo nu. A análise da geometria de iluminação foi feita por imagens obtidas do mesmo alvo em diferentes datas e em diferentes horários. Os resultados preliminares mostraram que a geometria de iluminação exerceu forte influência no fator de reflectância bidirecional dos alvos estudados.

Li e Strahler (1992) investigaram o efeito do sombreamento dentro das copas das árvores, os quais afetam a reflectância do dossel. O trabalho indicou que, em adição à geometria de iluminação e visada, a forma e a densidade das copas das árvores afetam a resposta espectral recebida pelo sensor. Como consequência, as curvas espectrais das copas iluminadas e sombreadas não são uniformes e a separação desses dois componentes podem aumentar a possibilidade de discriminar espécies com dados de sensoriamento remoto.

No trabalho de Gong et al. (1997), fundamentado em amostras de pixels das partes iluminadas dos dosséis, a exatidão da identificação florística aumentou em 13%, quando comparada com amostras coletadas em partes sombreadas e iluminadas conjuntamente.

Imagens dos satélites IKONOS e ETM+/Landsat foram utilizadas em um estudo desenvolvido por Thenkabail et al. (2003) para detectar a influência da topografia e de gradientes de umidade na predição de variáveis biofísicas (área basal e densidade de troncos) e composição de espécies em uma floresta na África central. Foram coletadas amostras em três porções do relevo, com diferentes graus de umidade, e em duas estações do ano: uma seca e uma úmida. Foi avaliada a importância do estresse hídrico sazonal na determinação da estrutura florística e na associação de espécies florestais. Os dados provenientes do IKONOS (reflectância das bandas individuais e índices de vegetação) mostraram maior sensibilidade às mudanças ocorrentes nas variáveis biofísicas e composição de espécies durante a estação seca em relação à estação úmida. Encontraram diferença significativa entre os valores de reflectância coletados na região do infravermelho próximo (banda 4) do IKONOS em relação aos sítios analisados, ou seja, nas três porções do relevo. Os dados ETM+/Landsat só apresentaram diferença significativa quando a partir deles foram determinados índices de vegetação.

Todos esses estudos consideraram a geometria de iluminação sem que houvesse uma interação dos ângulos zenitais e azimutais solares, bem como a interação desses com a topografia. Não houve também uma avaliação quantitativa e qualitativa desse processo em aplicações como identificação florística e estimativa de variáveis biofísicas utilizando dados de sensores remotos.



### 3 MATERIAL E MÉTODOS

#### 3.1 Área de estudo

O Município de Capão Bonito está localizado na Zona Fisiográfica do Paranapiacaba, Vale do Alto do Paranapanema, com acessos pelas SP 127 e SP 258, na Região Sudoeste do Estado de São Paulo, a 24°00'14" latitude sul e a 48°20'54" longitude oeste. Nesta posição há diferenças angulares do Sol nas diferentes estações do ano. Capão Bonito limita-se ao norte, com os municípios de Itapetininga; a leste, São Miguel Arcanjo ao sul, Ribeirão Grande e com Itapeva e Taquarivaí a oeste. Os principais rios que passam pelo município são: Rio das Almas, Rio Paranapanema e Ribeirão Paranapitanga. Distanto a 226 Km da capital, abrange uma área de 1.642 Km<sup>2</sup> e sua altitude média é de 705 m (CEPAM, 2005). No município estão presentes plantios de *Eucalyptus spp.* pertencentes à indústria Votorantim Celulose e Papel ( 3.1).

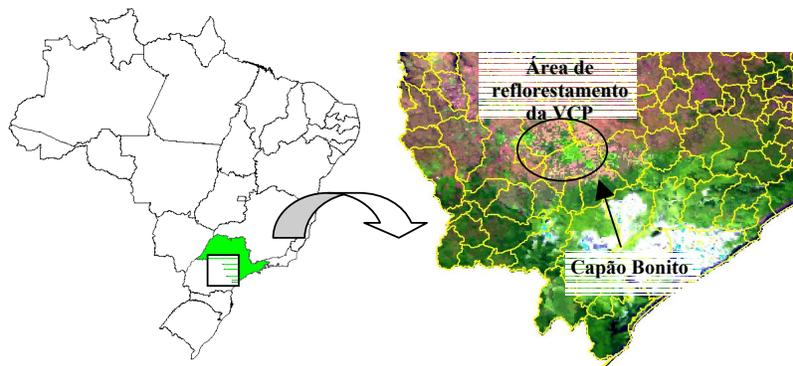


Figura 3.1 - Localização da área de estudo. Legenda: — limites municipais.

#### 3.1.1 Geomorfologia

O Município de Capão Bonito está localizado na Depressão Periférica Paulista e na Depressão do Paranapanema. O relevo predominante nesta unidade é constituído basicamente por colinas de topos convexos e tabulares. As altimetrias predominantes estão entre 600 e 700 m e as declividades das vertentes entre 10 e 20% (ROSS e MOROZ, 1997). Tais características geomorfológicas apontam para um relevo ondulado, o que implica em localidades com diferentes níveis de iluminação.

Os mesmo autores relatam ainda que a litologia desta unidade morfológica é basicamente constituída de arenito e arenitos eólicos. Toda a drenagem é tributária do Rio Paranapanema e apresenta um padrão paralelo. A região de Capão Bonito apresenta nível de fragilidade potencial médio e formas de dissecação média a alta, com vales entalhados e densidade de drenagem média a alta. Áreas sujeitas a forte atividade erosiva.

### **3.1.2 Clima**

Com base na classificação de Köppen, Setzer (1946) atribui para a região os tipos climáticos Cfa e Cfb, ambos sem estiagem. O clima Cfa definido como mesotérmico úmido, com temperaturas superiores a 22°C no verão e acima de 30mm de chuva no mês mais seco, sendo o índice pluviométrico entre 1100 a 1700 mm. O tipo Cfb, mesotérmico úmido, com a temperatura média do mês mais quente não atingindo a 22°C e precipitação de 1100 a 2000 mm, constituindo clima de região serrana. A imagem Hyperion foi adquirida no mês de agosto, período seco na região inclusive nos meses precedentes.

### **3.1.3 Solo**

Na região de Capão Bonito ocorrem principalmente os solos dos tipos Latossolos Vermelhos e Podzólicos Vermelho-Amarelos. Há o predomínio do Latossolo-Vermelho distrófico, com textura argilosa, ocorrente em relevo suave ondulado associado ao Argissolo Vermelho-Amarelo, também distrófico, com textura média/argilosa e arenosa/média, em relevo ondulado. No sul da área de estudo ocorre um representante da unidade Latossolo Vermelho-Amarelo, se apresentando distrófico, com textura argilosa e relevo ondulado associado ao Argissolo Vermelho-Amarelo, também distrófico, com textura média/argilosa e relevo ondulado e forte ondulado. Os Podzólicos Vermelho-Amarelos ocupam o norte e uma porção do sudoeste da área de estudo. Há outras variações associadas a Cambissolos Háplicos e Argissolos Vermelho-Amarelos, ambos encontrados em relevo ondulado e forte ondulado (OLIVEIRA et al., 1999). Em reflorestamentos o solo é coberto pelo dossel, além da serrapilheira e da

presença de subbosque em alguns locais, havendo então pouca interferência desse elemento na resposta espectral apresentada pela vegetação.

### **3.1.4 Vegetação**

A região de Capão Bonito está situada em uma área de contato entre a Savana e a Floresta Ombrófila, o que a caracteriza como área de Tensão Ecológica. Quando isso ocorre, as floras podem se justapor ou se interpenetrar, formando encaves ou ecótonos, respectivamente. Essas áreas à vezes são coincidentes com duas formações geológicas e com faixas de transição climática (IBGE, 2004).

A vegetação nativa da região foi na sua maior parte substituída por atividades agrícolas, incluindo pelos reflorestamentos, especialmente com espécies do gênero *Eucalyptus*. Segundo o IBAMA (2006), no município há também a presença de uma floresta nacional (Floresta Nacional de Capão Bonito) com cerca de 4.000 ha.

### **3.2 Sensor Hyperion**

O satélite EO-1 (*Earth Observing-1*), apresentado na Figura 3.2, foi lançado pela NASA (*National Aeronautics and Space Administration*) em 21 de novembro de 2000 para uma missão de demonstração e validação. Três sensores estão a bordo do EO-1: *Advanced Land Imager* (ALI), Hyperion e LAC (*LEISA Atmospheric Corrector*). O sensor Hyperion foi o primeiro sensor hiperespectral orbital, fornecendo uma nova classe de dados de observação e caracterização da superfície da Terra.

O satélite EO-1 possui uma órbita idêntica ao satélite Landsat 7, com uma defasagem temporal de 1 minuto, Sol-síncrona e uma altitude de 705 Km. A órbita possui uma inclinação de 98,2 graus, com um período orbital de 98,9 minutos. A velocidade do EO-1 é de 6,74 Km/s, passando pelo equador às 10:00 h, totalizando 14 órbitas por dia e a repetição do ciclo é a cada 16 dias.



Figura 3.2 - Satélite EO-1.  
Fonte: USGS (2005)

O sensor Hyperion coleta imagens com altas resoluções radiométrica (16 bits) e espectral. A resolução espacial das imagens geradas pelo sensor Hyperion é de 30 m e cada cena gerada possui 7,7 Km de largura por 42 Km de extensão, com uma extensão opcional de 185 Km (USGS, 2005). Nesse sensor há dois detectores separados para aquisição de imagens: um na região do VNIR (visível-infravermelho próximo) que abrange a região espectral de 356 a 1000 nm e outro no SWIR (infravermelho de ondas curtas), abrangendo a região de 900 a 2578 nm. Suas 242 bandas estão distribuídas no espectro eletromagnético (356 a 2578 nm) de maneira contígua (BECK, 2003).

Dentre as 242 bandas, 44 bandas não são calibradas. Uma razão da não calibração de todas as bandas é devido à diminuição da sensibilidade dos detectores dentro de certas regiões espectrais. As 198 bandas calibradas possuem uma cobertura completa do espectro eletromagnético de 356 a 2578  $\mu\text{m}$  e, devido a sobreposição entre as bandas dos detectores VNIR e SWIR (VNIR bandas 56-57 e SWIR bandas 77-78), restarão 196 bandas exclusivas no produto final (Tabela 3.1).

TABELA 3.1 – Bandas calibradas e não calibradas do sensor Hyperion

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

Fonte: [http://eo1.usgs.gov/userGuide/hyp\\_prod.html](http://eo1.usgs.gov/userGuide/hyp_prod.html)

O nível de correção disponível para as imagens Hyperion é o denominado como 1R, gerado pelo EO-1 *Product Generation System* (EPGS). Nesse nível são aplicadas somente correções radiométricas relativas mediante a aplicação de alguns algoritmos específicos (USGS, 2005). Como resultado, são disponibilizados dados de radiância no topo da atmosfera em unidades de radiância em  $mW / (cm^2 * Sr * \mu m)$ , quantizados em 16 bits.

### 3.3 Metodologia

O fluxograma contendo a metodologia utilizada está apresentado na Figura 3.3.

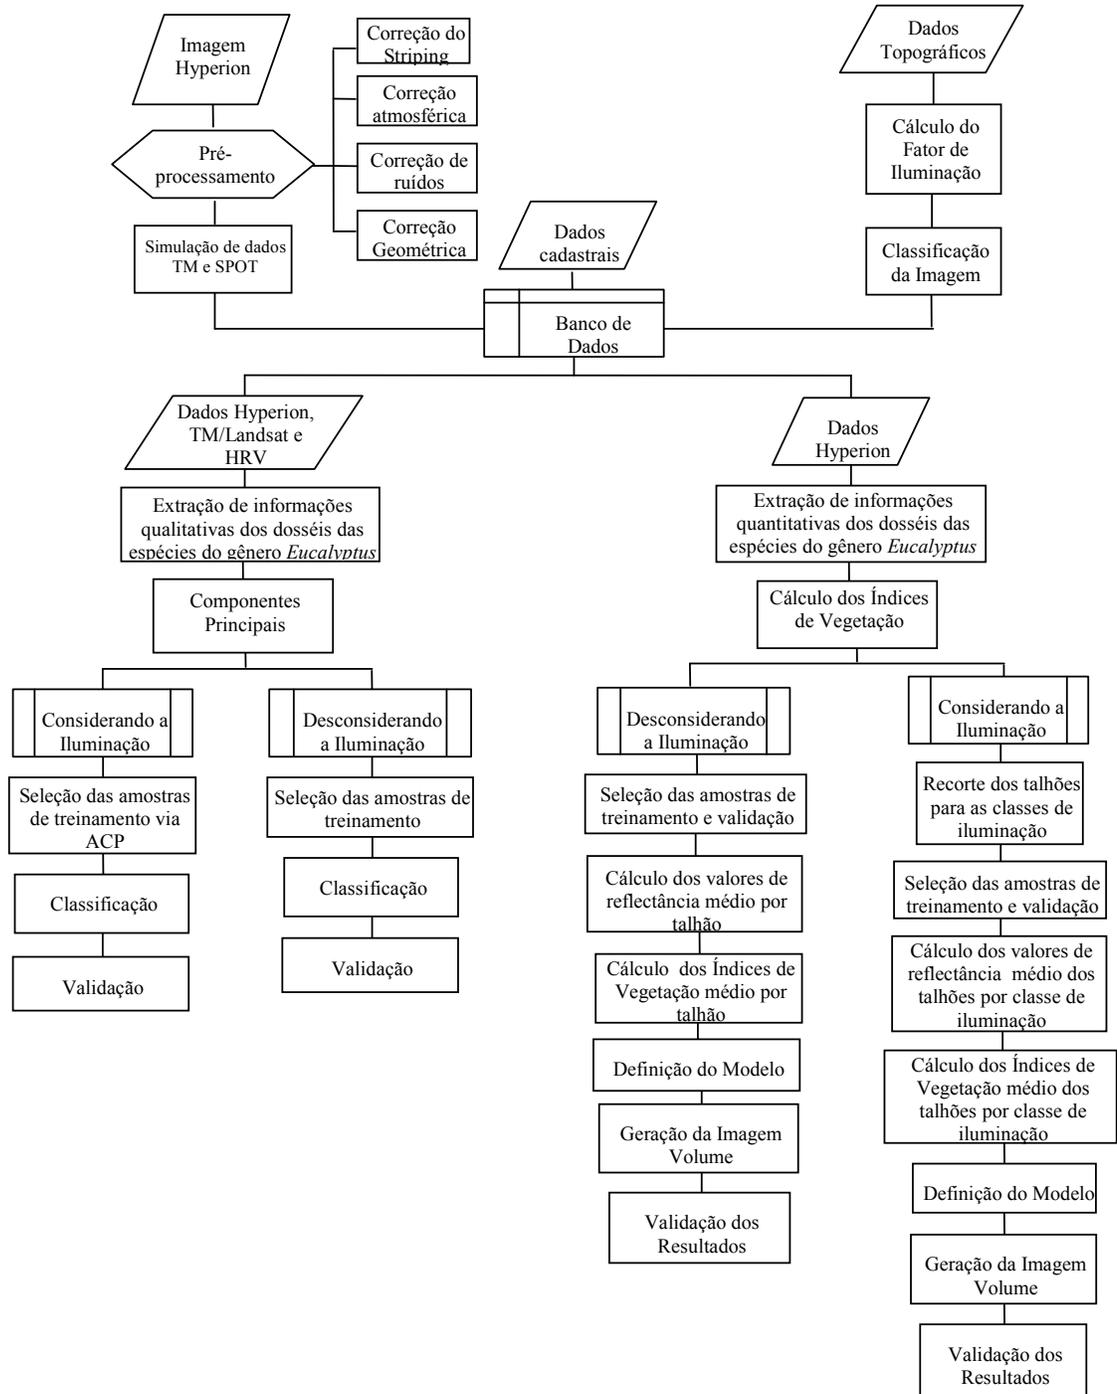


Figura 3.3 Fluxograma de Atividades

Primeiramente, será apresentada a imagem Hyperion adquirida para a área de estudo e toda a etapa de pré-processamento. Na seqüência será descrito como foi feita a simulação dos dados TM e HRV a partir das bandas da imagem Hyperion. Logo após serão apresentados os demais dados de entrada, como dados topográficos e dados cadastrais. Na próxima etapa será descrito como foi feita a extração de informações qualitativas dos dosséis das espécies do gênero *Eucalyptus* spp., ora denominada caracterização espectral dos dosséis, utilizando os dados dos três sensores (Hyperion, TM e HRV) e testada a influência da geometria de iluminação para esse tipo de estudo nas etapas considerando e desconsiderando a iluminação. Na etapa subsequente será apresentada a metodologia utilizada para extrair informações quantitativas dos dosséis das espécies do gênero *Eucalyptus* spp.. Essa etapa permitiu relacionar os dados hiperespectrais com a variável biofísica volume de madeira e a geração de modelos para espacializar essa variável, também testando a influência da geometria de iluminação (considerando e desconsiderando a iluminação).

### **3.3.1 Imagem Hyperion**

Como o sensor Hyperion não possui imageamento constante, foi feita uma pesquisa prévia para saber se haviam imagens disponíveis em catálogo que contemplassem plantios florestais dos gêneros *Pinus* spp. e/ou *Eucalyptus* spp. no Brasil. Foi então identificada uma grande área no município de Capão Bonito, Estado de São Paulo, com plantios de *Eucalyptus* spp. pertencentes à empresa Votorantim Celulose e Papel, referente ao dia 20 de agosto de 2003, a qual foi adquirida junto ao USGS (*United States Geological Survey*). A Figura 3.4 apresenta a localização da cena no terreno e o recorte da imagem Hyperion para a área de estudo.

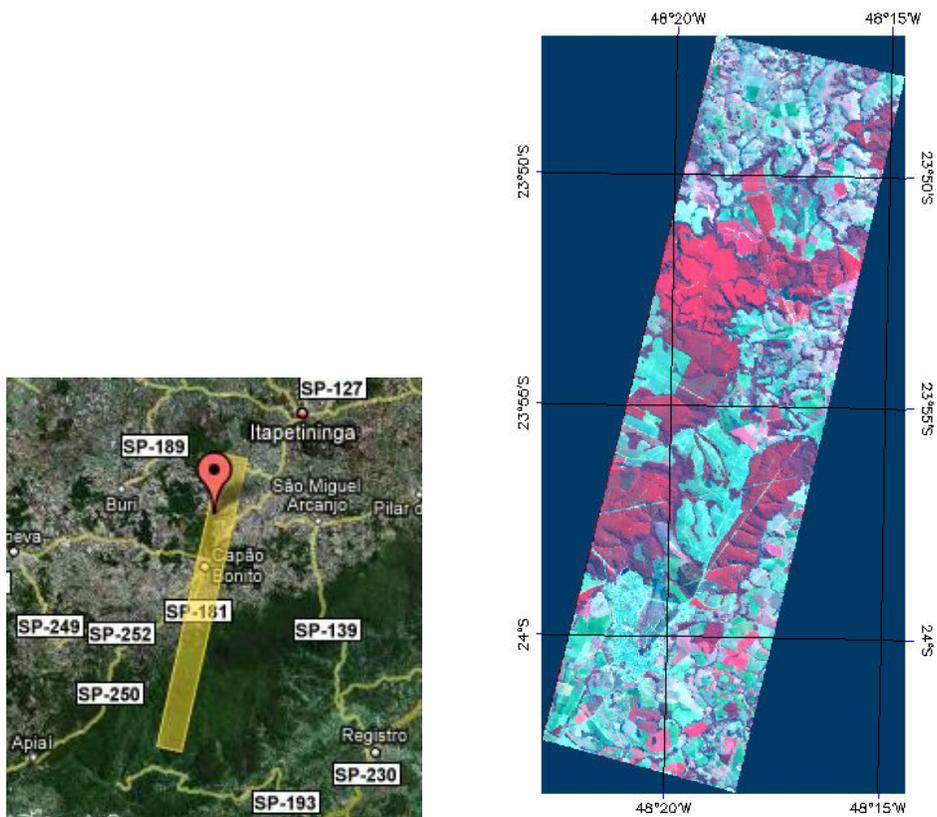


Figura 3.4 – Localização da cena Hyperion na região de Capão Bonito (à esquerda) e à direita o recorte para a área de estudo, composição colorida R (762,60 nm) G (660,85 nm) B (569,27 nm).  
 Fonte: USGS (2005).

A Tabela 3.2 apresenta as principais características da imagem utilizada. Essas características são referentes à cena inteira, ou seja, com 184 Km de comprimento.

TABELA 3.2 – Características da Imagem Hyperion

Data de Aquisição	20/08/2003
Canto NO	23°42'01.88"S, 48°17'36.72"O
Canto NE	23°42'56.20"S, 48°13'10.97"O
Canto SO	24°28'55.11"S, 48°28'58.16"O
Canto SE	24°29'49.69"S, 48°24'30.73"O
Hora Início da aquisição	13:00:06.885
Hora Final da aquisição	13:00:20.885
Órbita/ponto	220/76
Azimute Solar	46.150468
Elevação Solar	40.477187
Ângulo de Apontamento	Ao nadir

Fonte: USGS (2005)

### 3.3.2 Pré-processamento dos dados Hyperion

O pré-processamento da imagem Hyperion é uma etapa fundamental antes da análise dos dados. O sensor Hyperion, por estar em uma plataforma orbital e operar em bandas estreitas, possui uma relação sinal ruído modesta (~50:1) o que, juntamente com os efeitos atmosféricos, demanda uma etapa de pré-processamento, a qual inclui a correção atmosférica e a minimização dos ruídos na imagem (DATT et al., 2003).

#### 3.3.2.1 Correção do *striping*

Um tipo de ruído que a imagem Hyperion pode conter é o *striping*. Esse problema aparece especialmente nas primeiras 12 bandas do VNIR (*Visible Near InfraRed* ou visível e infravermelho próximo) e pode ocorrer em algumas bandas do SWIR (*Short Wave InfraRed* ou infravermelho de ondas curtas) para os dados provenientes do nível 1A. Esses “*striping*” *pixels* (pixels listrados) também podem ser chamados de pixels anormais e eles são classificados em quatro classes: contínuos, com valores atípicos de ND (Números Digitais); contínuos, com valores constantes de ND; intermitentes, com valores atípicos de ND e intermitentes, com baixos valores de ND. Acredita-se que essa falha ocorre pelas diferenças nas calibrações dos detectores (GOODENOUGH et al., 2003). Como o sensor Hyperion adquire dados no modo *pushbroom*, com um detector separado para cada coluna e para cada banda, esse problema pode ser causado por fatores como não-linearidade dos detectores ou efeitos de temperatura (KRUSE et al., 2003).

Nos dados Hyperion nível 1R, as três primeiras categorias de pixels anormais são corrigidas. A última categoria, pixels contínuos e com baixos valores de ND, ainda persiste. No geral, esses pixels anormais possuem valores mais baixos, quando comparados com os pixels vizinhos. A Figura 3.5 ilustra a presença de *striping* na imagem referente a agosto de 2003.



Figura 3.5 - Presença de *striping* nas bandas referentes aos comprimentos de onda de 467 e 518 nm, respectivamente.

Para a correção desses pixels foi desenvolvido um programa em linguagem IDL por Correia (2006). No programa (Apêndice A.1) foram identificadas as colunas que apresentavam o problema em cada banda, substituindo o valor do pixel com problemas pela média dos pixels vizinhos situados a sua direita e esquerda. Esse programa foi aplicado na imagem no aplicativo ENVI (*Environment for Visualising Images*) versão 4.2. Os resultados desse processamento são apresentados na Figura 3.6.

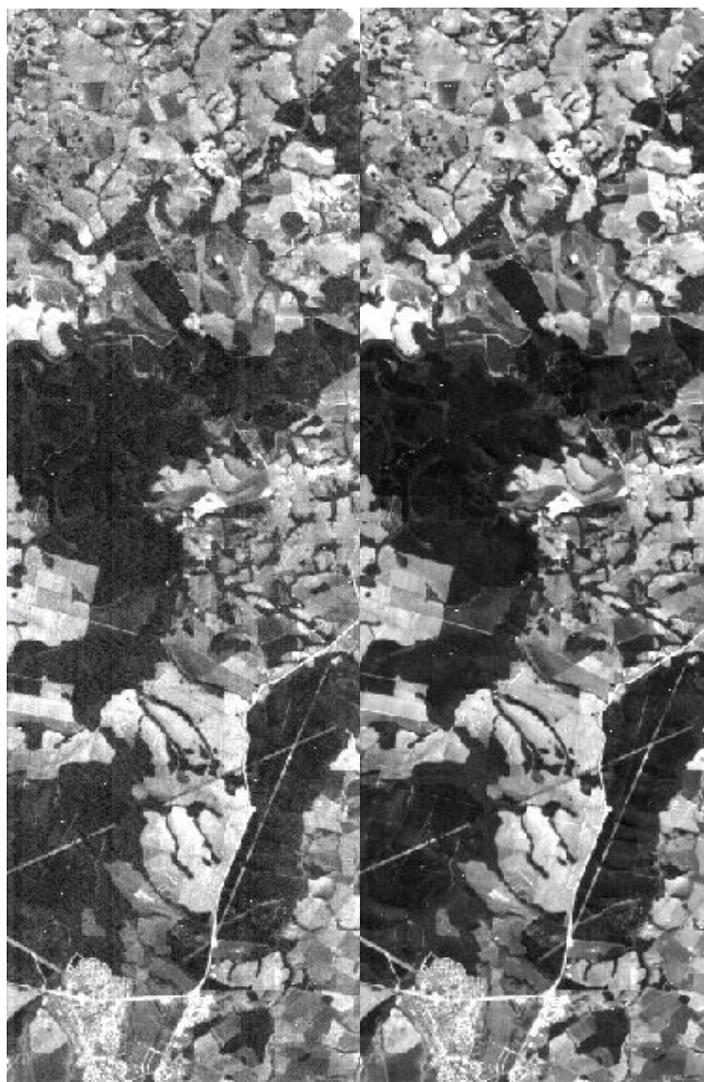


Figura 3.6 – Correção do *striping* nas bandas referentes aos comprimentos de onda de 467 e 518 nm, respectivamente.

### 3.3.2.2 Correção atmosférica

A correção atmosférica da imagem Hyperion foi feita utilizando o aplicativo FLAASH (*Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes*). O FLAASH utiliza uma equação padrão para a radiância de um pixel recebida por um sensor remoto,  $L^*$  (Equação 3.1), para uma superfície Lambertiana ou equivalente, desconsiderando a emissão termal do alvo.

$$L^* = A\rho/(1-\rho_e S) + B\rho_e/(1-\rho_e S) + L^*_a \quad (3.1)$$

Onde  $\rho$  é a reflectância de superfície para um determinado pixel,  $\rho_e$  é a reflectância de superfície média, S é o albedo esférico da atmosfera,  $L_a^*$  é a radiância retroespalhada pela atmosfera, e A e B são coeficientes que dependem das condições atmosféricas e geométricas. Cada uma dessas variáveis depende do comprimento de onda.

O primeiro termo da Equação 3.1 corresponde a radiância da superfície que chega diretamente ao sensor. O segundo termo da equação corresponde a radiância da superfície que é espalhada pela atmosfera e depois é captada pelo sensor. As constantes atmosféricas na Equação 3.1 são calculadas por um modelo de transferência radiativa, como o MODTRAN. Utilizando uma *look-up table* (LUT), essas constantes podem ser pré-calculadas e interpoladas para uma específica geometria de visada, condição atmosférica e comprimento de onda de interesse. Os valores de A, B, S e  $L_a^*$  dependem ainda da altitude do sensor, a qual inclui outras variáveis como coluna de vapor d'água, tipo de aerossol e visibilidade (MATTHEW et al., 2002). Os valores resultantes dessa correção atmosférica foram denominados de Fator de Reflectância Bidirecional de superfície ou FRB de superfície.

Para a correção atmosférica da imagem Hyperion foram escolhidas as variáveis apresentadas na Tabela 3.3. Para esse cálculo também foram considerados o tipo de sensor e o tamanho do pixel. O resultado da correção atmosférica de um pixel (alvo vegetação) pode ser observado na Figura 3.7. Esse tipo de correção está disponível no aplicativo ENVI 4.2.

TABELA 3.3 – Variáveis de entrada selecionadas para o aplicativo FLAASH.

Variáveis MODTRAN	
Visibilidade	50 Km
Data	20/08/2003
Latitude	-23.9217
Longitude	-48.3144
Altitude do Sensor	705 Km
Elevação do Terreno	0,660 Km
Modelo Aerossol	Rural
Modelo Atmosférico	Tropical
Feição de Absorção da Água	1135 nm

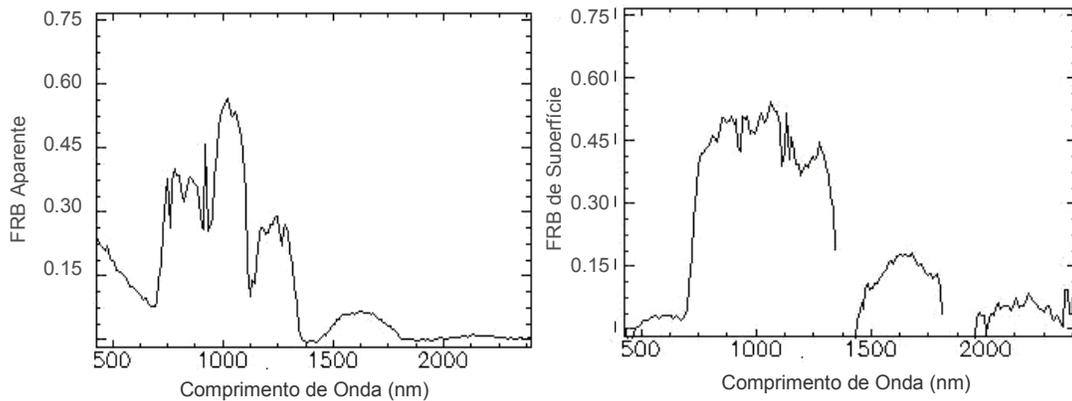


Figura 3.7 – Espectro de um pixel de vegetação antes e depois da correção atmosférica.

Após a correção atmosférica, os valores próximos a 1400 e 1900 nm foram excluídos, pois nesses comprimentos de onda há forte absorção da radiação eletromagnética pela atmosfera, restando somente ruídos.

### 3.3.2.3 Correção de ruídos na imagem

Após a correção atmosférica alguns ruídos ainda permanecem nas imagens de sensores hiperespectrais, seja por erros decorrentes das medições ou por erros nos modelos aplicados no processo de correção atmosférica. Para solucionar este problema podem ser aplicados métodos de ajuste como o EFFORT (*Empirical Flat Field Optical Reflectance Transformation*) e o MNF (*Minimum Noise Fraction*), os quais possibilitam amenizar os eventuais erros ainda remanescentes da etapa da correção.

Os métodos de ajuste removem artefatos consistentes em uma imagem hiperespectral atmosféricamente corrigida utilizando somente parâmetros da própria imagem. Para isso assume-se que toda cena contém pixels com valores constantes (“*smooth pixels*”) como estradas ou solo exposto, os quais podem ser identificados pela variância dos pixels referente a esse alvo, por exemplo. Por comparação com espectros de outros pixels na imagem (filtro de passa-baixa), esses espectros são utilizados para desenvolver uma correção linear na cena inteira (MATTHEW et al. 2002).

O EFFORT, disponível no aplicativo ENVI 4.2 foi aplicado apenas no segmento referente aos comprimentos de onda de 772 a 1275 nm (Figura 3.8).

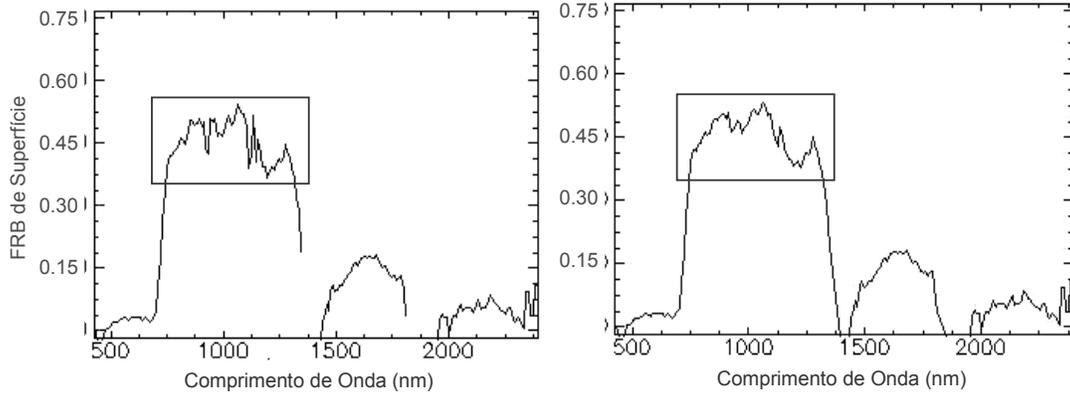


Figura 3.8 - Espectro de um pixel de vegetação antes e depois do EFFORT. Dentro do retângulo está a região espectral submetida ao polimento.

A técnica MNF foi utilizada na região do infravermelho médio. A transformação MNF determina a dimensionalidade inerente de dados da imagem, para segregar o ruído nos dados e para reduzir as exigências computacionais para processamentos subsequentes. Essa técnica permite remover o ruído dos dados executando a transformação *forward*, onde são determinadas quais as bandas que contém dados úteis (examinando as imagens e os autovalores) e somente essas bandas são utilizadas nessa transformação (DATT et al., 2003).

Para essa correção foram selecionados somente os dois platôs referentes aos comprimentos de onda de 1426 a 1810 nm e 1941 a 2395 nm. No aplicativo ENVI 4.2 foram selecionadas as bandas referentes a esse intervalo espectral e foram geradas as componentes MNF. Para a transformação inversa foram selecionadas as seis primeiras componentes por meio da análise do gráfico contendo os autovalores e da imagem referente a cada componente.

O espectro referente a um pixel de vegetação antes e após a aplicação da técnica MNF é apresentado na Figura 3.9. Após todas as correções foram excluídas as bandas com valores negativos, restando 158 bandas na imagem final.

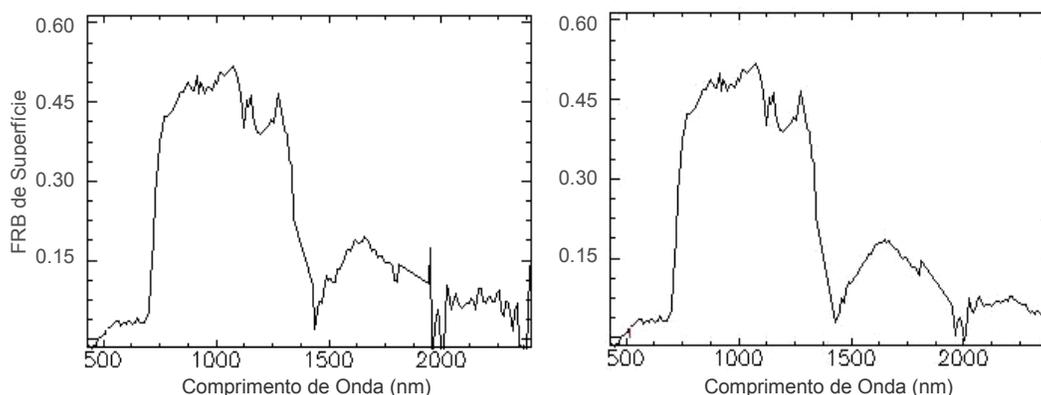


Figura 3.9 - Espectro de um pixel de vegetação antes e depois do MNF nas regiões de 1426 a 1810 nm e 1941 a 2395 nm.

### 3.3.2.4 Correção geométrica

A correção geométrica foi feita na imagem Hyperion tendo como base imagens georreferenciadas do sensor ETM+/Landsat disponíveis no *site* denominado Mr.Sid (<https://zulu.ssc.nasa.gov/mrsid/>). Após selecionar o mosaico contendo a área de estudo, a imagem foi recortada e importada para o ENVI 4.2, a qual foi utilizada como base para o georreferenciamento.

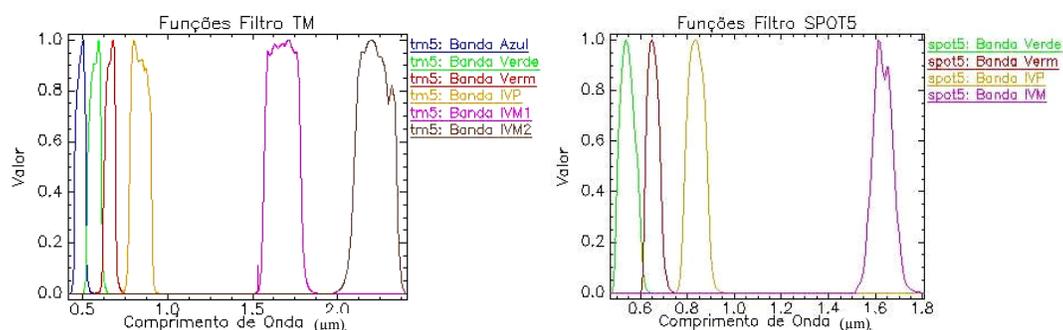
Foram selecionados 7 pontos de controle bem distinguíveis nas duas imagens para o georreferenciamento, tendo sido encontrados o erro total de 0,2565 pixel, ou seja, 7,69 m. A reamostragem dos pixels foi feita pelo método do vizinho mais próximo, o qual mantém o valor original de cada pixel.

### 3.3.3 Simulação de dados dos sensores HRV e TM

Para fins de comparação, foram simulados dados dos sensores TM do satélite Landsat e HRV do SPOT. Isso foi feito para verificar se os dados de um sensor hiperespectral oferecem vantagens no processo de caracterização dos dosséis florestais frente aos dados multiespectrais.

Utilizando a imagem Hyperion já corrigida foram simulados os dados para os sensores TM 5 e HRV 5. Esse procedimento foi feito no aplicativo ENVI 4.2 por meio da ferramenta *Spectral Resampling*, a qual possibilita que os dados provenientes de sensores

hiperespectrais sejam reamostrados para dados de um sensor conhecido ou para simulação de novos sensores, utilizando para isso funções-filtro específicas para cada sensor a ser simulado. Essas funções estão disponíveis em uma biblioteca espectral do ENVI. O valor para cada comprimento de onda tem que ter um peso entre 0 e 1, o qual é usado como fator multiplicativo nos dados que serão reamostrados. A Figura 3.10 mostra a biblioteca espectral das funções filtro para os sensores TM (referente ao satélite Landsat 5) e HRV (referente ao satélite SPOT 5) e os pesos (valores) adotados para cada comprimento de onda utilizado na simulação dos sensores de banda larga.



3.10 – Funções-filtro para os sensores TM 5 e HRV 5. Onde: IVP = Infravermelho Próximo, IVM = Infravermelho Médio.

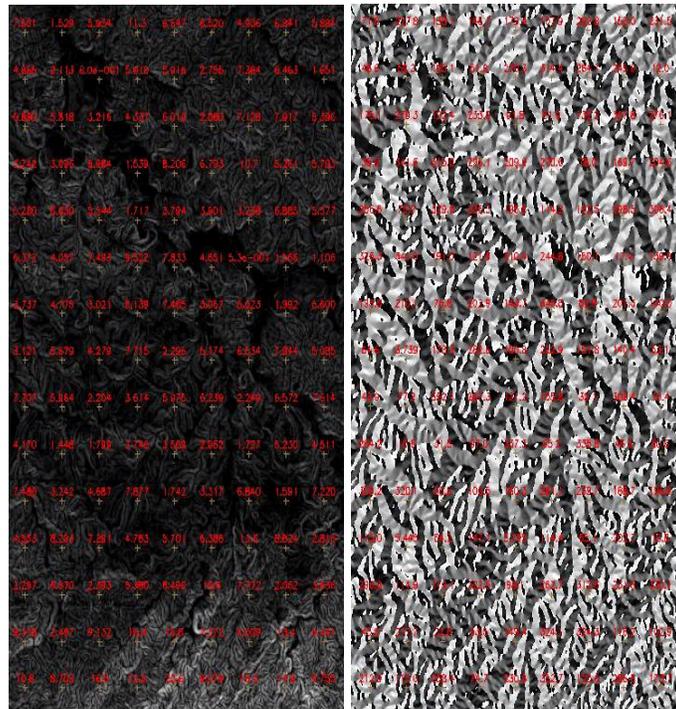
Fonte: biblioteca espectral das funções filtro do ENVI 4.2

Após esse procedimento foram geradas imagens simuladas para os sensores TM e HRV. Essas imagens foram utilizadas na etapa de caracterização espectral dos dosséis florestais juntamente com a imagem do sensor Hyperion. A banda na região do azul do sensor TM não foi utilizada, pois havia valores negativos para algumas amostras analisadas, o que dificultaria alguns procedimentos que seriam feitos posteriormente.

A redução nesse procedimento foi apenas espectral. Arai et al. (2005) avaliaram se a diminuição da resolução radiométrica de 16 para 8 bits afetava o resultado da classificação utilizando dados do sensor MODIS. A área de estudo contemplava o bioma floresta Amazônica, na região do lago Curuai – PA. O estudo concluiu que a redução da resolução radiométrica não afetou o resultado do estudo.

### 3.3.4 Dados topográficos

Os dados topográficos da área de estudo foram gerados por Valeriano (2004) e utilizaram como base dados SRTM (*Shuttle Radar Topography Mission*). A base de dados original foi extraída da Internet, no endereço da USGS (*United States Geological Survey*), onde os dados estão disponíveis com uma resolução espacial de 3" ou 90 m. O Modelo Digital de Elevação (MDE) original, derivado do SRTM foi convertido para um novo modelo, onde algumas características foram melhoradas como a resolução espacial de 3" para 1", remoção de falhas, redução de artefatos e distribuição da aleatoriedade. A interpolação por krigeagem foi utilizada para gerar o novo MDE. Foram geradas variáveis básicas locais, obtidas com operações de vizinhança, como a declividade do terreno ou ângulo zenital, orientação das vertentes ou ângulo azimutal (VALERIANO, 2005). A Figura 3.11 ilustra esses produtos obtidos para a área de estudo.



3.11 – Produtos SRTM: Declividade e Orientação das Vertentes

Essas informações permitiram a identificação de locais que, no momento da passagem do satélite, tivessem condições de iluminação idênticas. Para isso foi calculado o Fator de Iluminação o qual é demonstrado na Equação 3.2 (VALERIANO, 2006):

$$FI = \sqrt{((\cos(\varphi_{x,y} - \varphi_s) + (\cos(\theta_{x,y} - \theta_s)))^2} \quad (3.2)$$

Onde:

$\varphi_{x,y}$  = orientação das vertentes ou imagem azimute

$\varphi_s$  = azimute solar (no momento de aquisição da imagem)

$\theta_{x,y}$  = declividade ou imagem zênite

$\theta_s$  = zênite solar (no momento de aquisição da imagem)

Essa equação não contempla o ângulo de visada do sensor, pois o mesmo se encontra ao nadir.

A equação foi inserida no ENVI 4.2 e, por meio da ferramenta matemática de bandas, foi gerada a imagem “Fator de Iluminação”. A imagem resultante foi fatiada em classes, as quais foram definidas de acordo com a iluminação que o terreno estaria recebendo no momento de aquisição da imagem, considerando o relevo. Optou-se então por uma classe onde as árvores estariam plantadas em terreno plano e recebendo raios solares de maneira uniforme, denominada plano. Duas classes onde as árvores estavam se desenvolvendo em terreno inclinado e recebendo iluminação direta (muito iluminado e iluminado) e duas classes também em terreno inclinado, porém recebendo iluminação de forma indireta (pouco iluminado e escuro). Utilizando o processo de fatiamento, foi gerada uma imagem com essas classes no aplicativo SPRING 4.2. A classe muito iluminado foi descartada, pois haviam poucos pixels representantes na área de estudo.

### 3.3.5 Dados cadastrais

Dados referentes à área de estudo como espécie, idade da planta, ano de plantio, tipo de solo, espaçamento, associado aos vetores (*shapes*) referente a cada talhão (Figura 3.12) foram fornecidos pela empresa Votorantim Celulose e Papel (VCP) e inseridos em um banco de dados georreferenciado no aplicativo SPRING 4.2.

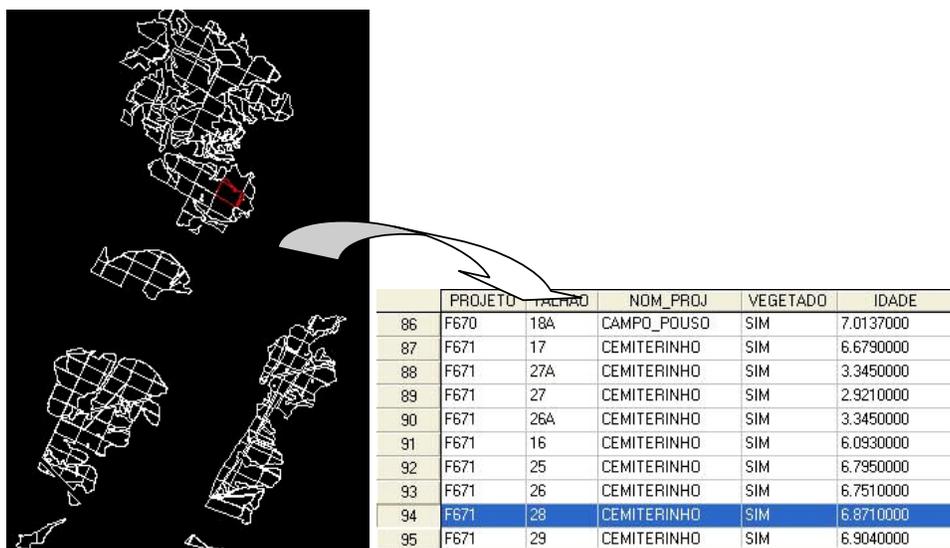


Figura 3.12 – Exemplo de vetores dos talhões com as tabelas associadas inseridos no banco de dados.

A área dos talhões estava compreendida entre 3 e 44 hectares, com um valor médio de 18 hectares. Os dados biofísicos dos plantios também foram fornecidos pela VCP, pois se tratavam de dados históricos referentes ao ano de 2003. A metodologia utilizada para a amostragem de campo pela VCP é a amostragem por parcelas de tamanho variável, compreendendo 60 árvores, ou seja, 6 linhas de 10 árvores, a qual é esquematizada na Figura 3.13. Nessas parcelas são coletados dados referentes à Circunferência a Altura do Peito (CAP), altura das 5 árvores dominantes, altura das árvores da primeira linha (=10). Como as parcelas são de tamanho variável, após demarcar as 60 árvores são medidos seis comprimentos (todas as filas) e duas larguras (entre as árvores 1 e a 60 e entre as árvores 10 e 51) para o cálculo do tamanho da parcela.

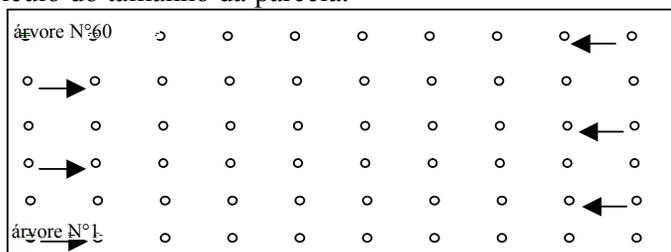


Figura 3.13 – Esquema de medição das árvores dentro de uma parcela. As setas mostram o sentido de caminhamento para cada linha.

As alturas são medidas utilizando um hipsômetro de Haga. Os dados referentes ao CAP, altura das árvores e tamanho da parcela servem de base para o cálculo de volume de madeira ( $\text{m}^3.\text{ha}^{-1}$ ).

Para que o volume de madeira fosse referente a data de passagem do sensor, ou seja, 20/08/2003, utilizou-se a Equação 3.3 citada por Scolforo (1998).

$$I_n V_2 = \beta_0 + \beta_1 S^{-1} + \beta_2 I_2 + \beta_3 (I_1 / I_2) I_n G_1 + \beta_3 \alpha_0 [1 - (I_1 / I_2)] + \beta_3 \alpha_1 S [1 - (I_1 / I_2)] \quad (3.3)$$

Onde:

$I_1$  = Idade inicial (em anos);

$I_2$  = Idade de projeção (em anos);

$V_2$  = Volume ( $\text{m}^3/\text{ha}$ ) projetado para a idade  $I_2$ ;

$S$  = Índice de sítio;

$\beta_{is}$  = Parâmetros a serem estimados;

$\alpha_{is}$  = Coeficientes de regressão;

$G_1$  = área basal ( $\text{m}^2/\text{ha}$ ) na idade  $I_1$ ;

Os dados de volume foram calculados por talhão pela VCP e em seguida foram inseridos no banco de dados.

### **3.3.6 Caracterização espectral dos dosséis das espécies do gênero *Eucalyptus* spp.**

A caracterização espectral teve início por meio de um processo de classificação, onde amostras de treinamento foram coletadas para cada espécie, tentando assim identificar a ocorrência dessas espécies em toda a área de estudo.

Esse procedimento foi conduzido utilizando dados do sensor Hyperion e aqueles simulados TM e HRV. Para o processamento dos dados de cada sensor foram seguidos os passos descritos a seguir. Essa metodologia foi concebida considerando e não considerando a iluminação do terreno no momento da aquisição da imagem, baseado nas classes de iluminação obtidas no item 3.3.4.

Uma análise *a priori* foi feita para selecionar as espécies do gênero *Eucalyptus* que possuíam um número de pixels representativo em termo de área e que os talhões contemplassem as quatro classes de iluminação analisadas. Foram então selecionadas cinco espécies, as quais satisfaziam essa condição, e para cada uma foram coletadas 80 amostras espectrais, ou seja, valores FRB de superfície, para cada classe de iluminação (iluminado, plano, pouco iluminado e escuro), totalizando 320 amostras para cada espécie. Esse procedimento se repetiu para as imagens Hyperion, TM e HRV, e os dados espectrais foram armazenados em uma planilha.

### **3.3.6.1 Componentes Principais**

O cálculo das componentes principais é um método bem conhecido de transformação estatística muito utilizada no sensoriamento remoto. Muitas vezes, o estudo e a interpretação de um conjunto de dados envolvem a análise de muitas variáveis, podendo tornar o trabalho demorado e suscetível a erros e a perdas de informações importantes. As componentes principais no sensoriamento remoto visam à geração de imagens não correlacionadas com o objetivo de separar ruídos das imagens e ainda para reduzir a dimensionalidade dos dados. Devido ao fato de que bandas multiespectrais são altamente correlacionadas, a transformação componentes principais é utilizada para produzir imagens resultantes não correlacionadas. Isso é feito reescrevendo as coordenadas de amostras em outro sistema de eixo, ou seja, as variáveis originais geram, por meio de combinações lineares, componentes principais em um número igual às variáveis de entrada. As componentes principais são então obtidas em ordem decrescente de variância onde a componente principal 1 retém mais informação estatística que a componente principal 2 e assim por diante e última componente principal geralmente contém ruídos (JOLLIFFE, 2002; RICHARDS e JIA, 2006).

Como resultados da aplicação dessa técnica têm-se o autovetor, autovalor de cada componente principal, além do fator referente a cada amostra que gerou a componente principal. O autovalor representa a contribuição relativa de cada componente para explicar a variação total dos dados, existindo um autovalor para cada componente. Autovetor fornece o valor que representa o peso de cada variável em cada componente

(eixos) e representa os coeficientes de correlação. As variáveis com elevado autovetor no primeiro eixo tendem a ter autovetor inferior no segundo eixo. O processo de extrair mais eixos segue até igualar-se ao número de variáveis ou bandas, porém os eixos posteriores vão contribuir cada vez menos para explicar a variância dos dados. Dependendo do sensor utilizado, os dois primeiros eixos são suficientes para explicar a variância dos dados e pela facilidade de interpretação de um gráfico em duas dimensões (GALVÃO, 2001; RICHARDS e JIA, 2006; SCHOWENGERDT, 2007).

Vale salientar que considerando a relativa similaridade entre curvas do FRB de superfície provenientes de diferentes tipos de dosséis (no caso deste trabalho, de diferentes plantios florestais), a aplicação da técnica de principais componentes teve também como objetivo permitir a identificação ou a quantificação de diferenças nessas curvas, mesmo que de caráter médio, contrariamente ao que acontece em geologia ou em mineralogia, quando é interessante identificar diferenças pontuais nessas curvas como picos ou vales representativos de aumento ou de diminuição de reflectância, dinâmica esta geralmente associada a aspectos específicos da composição química e/ou estrutural do material em estudo.

A aplicação das componentes principais então, se por um lado dificulta essa identificação pontual, acaba facilitando a identificação de diferenças médias de reflectância ao longo de grandes extensões do espectro. É fácil concluir que tal mediação apresentará resultados diferenciados dependendo da resolução espectral empregada. Assim, decidiu-se pelo emprego das componentes principais para a discriminação dos diferentes tipos de dosséis (plantios), considerando também diferentes resoluções espectrais (dados Hyperion, TM e HRV).

De posse da planilha com os valores do FRB de superfície para todas as amostras coletadas, e para cada sensor, foram feitos os cálculos das componentes principais no aplicativo SPSS (*Statistical Package for the Social Sciences*) versão 10.0.

Utilizando os autovetores gerados para cada banda, foram calculadas as imagens Componente Principal 1 e 2 por meio da ferramenta *Band Math* do ENVI 4.2., para os sensores Hyperion, TM e HRV.

Os fatores gerados para cada amostra e referente aos três sensores foram salvos em uma tabela os quais foram utilizados para a seleção das amostras de treinamento.

### **3.3.6.2 Considerando a iluminação**

Nessa etapa foi feita uma classificação onde as amostras de treinamento foram selecionadas levando em consideração a geometria de iluminação, ou seja, as classes de iluminação resultantes do item 3.3.4. Para isso foram seguidos três passos: a seleção das amostras de treinamento, a classificação e a validação dos resultados, os quais são descritos a seguir.

#### **3.3.6.2.1 Seleção das amostras de treinamento**

A seleção das amostras de treinamento utilizou os fatores obtidos pela análise de componentes principais. Isso foi feito para que pudessem ser identificadas quais amostras referentes a cada espécie se separavam e em quais condições de iluminação. Com os fatores obtidos pela transformação Componentes Principais para cada amostra, ou seja, 80 ROIs (Region of Interest) de 1 pixel para cada classe de iluminação e para cada uma das cinco espécies, foram gerados gráficos para os dados de cada sensor, onde o eixo x representava os fatores referentes à componente principal 1 (PC1) e o eixo y os fatores da componente principal 2 (PC2). Para facilitar a visualização foram adotadas cores diferenciadas para cada espécie e para cada classe de iluminação.

Esses fatores explicam o padrão das correlações dentro de um conjunto de dados de variáveis observadas. Eles podem ser usados para avaliar a interdependência das variáveis e para o delineamento de padrões, onde cada padrão aparecerá como um fator, sendo possível o delineamento de agrupamentos com características ou comportamentos similares (RUMMEL, 1970).

De posse desses gráficos, foi feita uma análise visual da distribuição espacial dessas espécies nos dois planos (PC1 e 2) de onde foi possível definir *clusters* ou agrupamentos de pontos para cada espécie, identificando-se assim, em quais classes de iluminação essas espécies não se misturavam.

Foram então selecionadas as amostras referentes a essas classes e identificadas as suas coordenadas geográficas, o que permitiu a localização de cada amostra sobre a imagem de satélite. Essas amostras foram nomeadas como amostras de treinamento e utilizadas no processo de classificação. Esse procedimento foi feito separadamente para cada sensor.

### 3.3.6.2.2 Classificação

A classificação foi feita utilizando a imagem calculada a partir dos autovetores gerados pela análise das componentes principais (Componente Principal 1 e 2) para os três sensores analisados nesse trabalho.

O método utilizado para esse procedimento foi a classificação supervisionada e as amostras de treinamento foram aquelas selecionadas no item 3.3.6.2.1. O classificador escolhido foi a Distância de Mahalanobis.

A fórmula da Distância de Mahalanobis é dada por:

$$D^2 = (x - m)^T C^{-1} (x - m) \quad (3.4)$$

Onde

$D^2$  = distância de Mahalanobis

$x$  = vetor de dados

$m$  = vetor dos valores médios das variáveis independentes

$C^{-1}$  = matriz de covariância inversa das variáveis independentes

$T$  = indica vetor transposto

A distância de Mahalanobis constitui um critério de determinar a similaridade entre um conjunto de dados desconhecido de um conjunto conhecido. Esse método tem sido aplicado com sucesso na discriminação espectral de alvos e uma das razões para isso é que a distância de Mahalanobis é sensível às mudanças inter-variáveis das amostras de treinamento. A distância de Mahalanobis é medida em termos de desvios padrões em relação à média das amostras de treinamento e como resultado obtém-se uma medida

estatística de quão bem os espectros de amostras desconhecidas se aproximam dos espectros das amostras de treinamento ou conhecidas (RICHARDS e JIA, 2006).

### **3.3.6.2.3 Validação dos resultados**

A partir dos *shapes* contendo as informações a respeito dos talhões, foi identificada a espécie presente em cada talhão e foi confeccionado um mapa “Verdade de Campo”. A validação foi feita pelo cruzamento da imagem gerada no processo de classificação pela imagem “Verdade de Campo”, resultando em índices Kappa.

O resultado obtido pelo sensor Hyperion foi comparado com os resultados obtidos pelos sensores TM e HRV, cruzando-se as duas planilhas e gerando matrizes de confusão (Hyperion x TM e Hyperion x HRV). Como resultado dessas matrizes é obtido o índice Kappa. Se o mesmo for próximo a 1 indica que os resultados das classificações são iguais.

### **3.3.6.3 Desconsiderando a iluminação**

Aqui a geometria de iluminação foi desconsiderada para que os resultados da classificação fossem comparados com os resultados obtidos considerando a geometria de iluminação, podendo assim avaliar a influência da mesma no processo de caracterização dos dosséis de plantios do gênero *Eucalyptus*.

Para esta etapa foram coletadas amostras para cada uma das cinco espécies sem que a geometria de iluminação fosse considerada. Para isso as amostras de treinamento foram coletadas nas quatro classes de iluminação, de maneira aleatória, sem que essas classes fossem discriminadas. Essas amostras foram localizadas pelas suas coordenadas geográficas sobre as imagens de satélite e foram utilizadas no processo de classificação.

As imagens utilizadas no processo de classificação também foram aquelas geradas pela análise das componentes principais (item 3.3.6.1) para os três sensores. Foi feita então a classificação pelo método Distância de Mahalanobis, com o mesmo limiar utilizado na classificação que considerou a iluminação. Os resultados considerando e desconsiderando

a iluminação para cada sensor foram comparados por meio das matrizes de confusão e novamente foi avaliado o índice Kappa entre essas matrizes.

### **3.3.7 Relação entre dados hiperespectrais e o volume de madeira**

Utilizando os dados de volume referentes a cada talhão fornecidos pela VCP para o ano de 2003, foram relacionados os volumes médios de madeira por talhão com os dados obtidos pelo sensor Hyperion com o FRB de superfície e índices de vegetação calculados a partir de bandas largas e estreitas.

Esse procedimento foi realizado desconsiderando e considerando a iluminação no terreno no momento da aquisição da imagem, baseado na imagem classificada obtida no item 3.3.4, possibilitando assim a avaliação da influência da geometria de iluminação nesse tipo de estudo.

#### **3.3.7.1 Cálculo dos Índices de Vegetação**

Um passo anterior à relação dos dados hiperespectrais com a biomassa foi o cálculo dos índices de vegetação, os quais tiveram avaliado a sua potencialidade na espacialização de dados de volume de madeira.

Índices de Vegetação são as combinações do FRB de superfície determinados em dois ou mais comprimentos de onda que estão associados a uma propriedade particular da vegetação. Eles têm sido concebidos levando em consideração as propriedades espectrais de folhas isoladas ou de dosséis vegetais (JENSEN, 2000).

Os Índices de Vegetação foram calculados a partir de funções específicas do aplicativo ENVI 4.2 quando do processamento de dados hiperespectrais dentro do intervalo espectral compreendido entre 400 a 2500 nm.

Foram então calculados os seguintes índices de vegetação:

- 1) *Normalized Difference Vegetation Index* ou Índice de Vegetação da Diferença Normalizada: Esse índice é um dos primeiros e mais utilizados índices de vegetação. Ele baseia-se na alta absorção e reflectância da clorofila na região do

vermelho e na alta reflectância causada pelas estruturas internas da folha na região do infravermelho próximo do espectro eletromagnético. Ele pode saturar em vegetações densas com LAI (*Leaf Area Index* ou Índice de Área Foliar) elevado. O valor de NDVI varia entre -1 e 1. Geralmente em vegetações verdes e saudáveis o índice fica em torno de 0,2 e 0,8 (ROUSE et al., 1973).

$$NDVI = \frac{\rho_{IVP} - \rho_{VERM}}{\rho_{IVP} + \rho_{VERM}} \quad (3.3)$$

- 2) *Red Edge NDVI* ou Índice de Vegetação da Diferença Normalizada na Borda Vermelha: esse índice é uma modificação do tradicional NDVI e é utilizado em dados com alta resolução espectral e difere do NDVI porque utiliza bandas na borda vermelha ao invés dos picos principais de absorção e reflectância da clorofila. O índice NDVI<sub>705</sub> é sensível a pequenas mudanças do conteúdo foliar do dossel e senescência. Seu valor varia de -1 a 1 e a amplitude comum em vegetação verde é de 0,2 a 0,9 (GITELSON e MERZLYAK, 1994).

$$NDVI_{705} = \frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705}} \quad (3.4)$$

- 3) *Vogelmann Red Edge Index* ou Índice de Vegetação da Diferença Normalizada na Borda Vermelha de Vogelmann 1: é um índice calculado a partir de dados de reflectância de bandas estreitas o qual é sensível aos efeitos combinados da concentração da clorofila na folhagem, área foliar do dossel e conteúdo de água nas folhas. É utilizado em estudos da fenologia da vegetação (inclusive crescimento), agricultura de exatidão e modelagem da produtividade da vegetação. O valor desse índice fica entre 0 e 20 mas em vegetação verde são geralmente encontrados valores entre 4 e 8 (VOGELMANN et al., 1993).

$$VOG_1 = \frac{\rho_{740}}{\rho_{720}} \quad (3.5)$$

- 4) *Photochemical Reflectance Index* ou Índice de Reflectância Fotoquímica: é um índice sensível às mudanças nos pigmentos carotenóide (principalmente a xantofila) na folhagem. Os pigmentos carotenóides são indicativos da eficiência do uso da luz fotossintética ou a taxa de dióxido de carbono armazenada pela folhagem por unidade de energia absorvida. Esse índice é usado em estudos de estresse e produtividade da vegetação. Os valores variam entre -1 e 1 e valores comuns para vegetação verde ficam entre -0,2 e 0,2 (GAMON et al., 1992).

$$PRI = \frac{\rho_{531} - \rho_{570}}{\rho_{531} + \rho_{570}} \quad (3.6)$$

- 5) *Anthocyanin Reflectance Index 1* ou Índice de Reflectância da Antocianina: esse índice é sensível à antocianina presente na folhagem e um aumento no seu valor indica mudanças na folhagem do dossel seja por crescimento da planta ou morte. Os valores variam de 0,001 a 0,1 (GITELSON et al., 2001).

$$ARI_1 = \left( \frac{1}{\rho_{550}} \right) - \left( \frac{1}{\rho_{700}} \right) \quad (3.7)$$

- 6) *Water Band Index* ou Índice da Banda de Água: é sensível a quantidade de água no dossel . Com o aumento do conteúdo de água em dosséis vegetais, a forte absorção de água que ocorre em 970 nm passa a ocorrer em 900 nm. É utilizado em análise de estresse do dossel, predição e modelagem de produtividade, análise da condição do perigo de fogo e estudos fisiológicos de ecossistemas. A variação para esse índice é entre 0,8 e 1,2 (PENUELAS et al., 1996).

$$WBI = \frac{\rho_{900}}{\rho_{970}} \quad (3.8)$$

- 7) *Moisture Stress Index* ou Índice de Estresse Hídrico: é sensível ao aumento do conteúdo de água foliar. Com o aumento do conteúdo de água nas folhas de um dossel a banda de absorção em torno de 1599 nm aumenta. A absorção em 819 nm não é afetada pela alteração do conteúdo de água servindo então como

referência. Nesse índice altos valores indicam estresse hídrico ou baixo conteúdo de água nas folhas. As aplicações desse índice são as mesmas do *Water Band Index*. Os valores variam de 0 a mais de 3 e os valores mais comumente encontrados em vegetações verdes são de 0,4 a 2 (HUNT JR. e ROCK, 1989).

$$MSI = \frac{\rho_{1599}}{\rho_{819}} \quad (3.9)$$

8) *Normalized Difference Infrared Index* ou Índice Infravermelho da Diferença Normalizada: também é sensível a mudanças no conteúdo de água no dossel. Usa a formulação da diferença normalizada em vez de uma relação simples e os valores aumentam com o aumento do conteúdo de água. Dentre as aplicações estão o manejo agrícola, monitoramento do dossel florestal e detecção de estresse. Varia de -1 a 1 e os valores mais encontrados na vegetação verde são em torno de 0,02 e 0,6 (HARDISKY et al., 1983).

$$NDII = \frac{\rho_{819} - \rho_{1649}}{\rho_{819} + \rho_{1649}} \quad (3.10)$$

Alguns índices foram adaptados para comprimentos de onda disponíveis no sensor Hyperion.

### **3.3.7.2 Relação entre dados hiperespectrais e volume de madeira desconsiderando a iluminação**

Primeiramente foi feito todo o procedimento desconsiderando a iluminação e logo em seguida considerando a iluminação. Os resultados dos dois métodos foram comparados e foi avaliada a influência da geometria de iluminação no processo de espacialização da variável volume de madeira obtido a partir de dados do sensor Hyperion.

#### **3.3.7.2.1 Seleção dos talhões para geração do modelo e para validação**

Para os 126 talhões de *Eucalyptus* spp. presentes na área de estudo, foi feita uma seleção aleatória que resultou na identificação e separação de 70% dos talhões para gerar o modelo e 30% serviram para a validação, ou seja, dados de 88 talhões foram utilizados

para gerar o modelo de regressão e dos outros 38 talhões para validar os resultados obtidos.

### 3.3.7.2.2 Cálculo dos valores do FRB de superfície médio por talhão

Os valores do FRB de superfície foram extraídos dos 88 talhões, utilizando para isso os polígonos referentes a cada talhão (Figura 3.14) sobrepostos à imagem Hyperion. O FRB de superfície médio por talhão e para 158 bandas foi calculado e os valores foram dispostos em uma planilha eletrônica (Tabela 3.4).

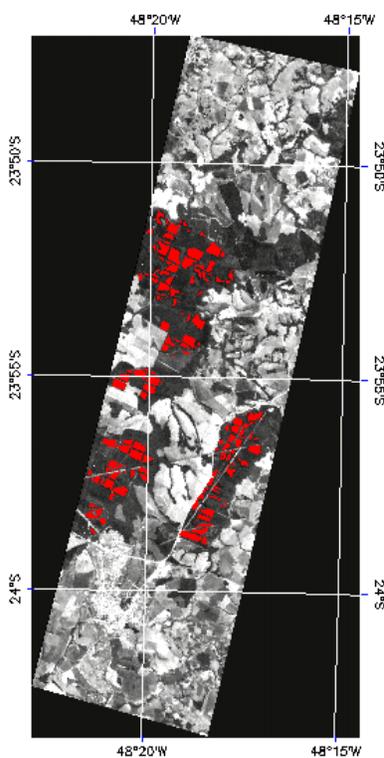


Figura 3.14 – Localização dos 88 talhões selecionados para geração do modelo.

### 3.3.7.2.3 Cálculo dos Índices de Vegetação médio por talhão

Utilizando dados dos mesmos 88 talhões, foi calculado o valor médio por talhão para cada imagem “Índice de Vegetação”, os quais também foram inseridos em uma planilha eletrônica (Tabela 3.4). Esse procedimento foi feito para os oito índices de vegetação gerados.

### 3.3.7.2.4 Definição do modelo de regressão

Na planilha contendo os dados dos 88 talhões selecionados para geração do modelo, como o FRB de superfície média de talhão e os valores médios referentes a cada índice de vegetação por talhão, foram inseridos ainda dados de volume de madeira por talhão, fornecidos pela empresa VCP e calculados para a data de passagem do sensor, ou seja, 20/08/2003. Na Tabela 3.4 está um exemplo de como os dados foram organizados.

TABELA 3.4 – Exemplo de organização dos dados coletados nos talhões selecionados para a geração do modelo.

Projeto	Talhão	Volume de Madeira (m <sup>3</sup> /ha)	Comprimento de Onda			Índices de Vegetação		
			508,22	518,39	528,57...	NDVI	Red Edge NDVI	Vogelmann Red Edge Index 1...
Campo de Pouso	12	149,41	96,97	120,66	157,42	0,84	0,71	2,82
Campo de Pouso	14	152,8	109,54	135,39	176,12	0,86	0,73	2,82
Campo de Pouso	15	141,86	109,90	140,69	180,43	0,85	0,72	2,77
Campo de Pouso	17	166,66	103,55	129,15	172,52	0,86	0,73	2,77
Campo de Pouso	18	123,66	146,54	170,45	210,86	0,77	0,65	2,56
Cemiterinho	17	137,43	98,16	124,24	160,64	0,84	0,69	2,53
Cemiterinho	24	165,96	95,31	123,00	163,38	0,86	0,72	2,65
Cemiterinho	27	387,85	59,42	88,86	131,09	0,91	0,77	2,88
Cemiterinho...	29	124,01	93,99	122,45	160,34	0,85	0,69	2,48

Foi aplicada a regressão linear múltipla onde os dados de volume de madeira de cada talhão foram considerados como a variável dependente (Y) e os valores do FRB de superfície e os índices de vegetação nesses talhões como variáveis independentes (X<sub>i</sub>), como mostra a Equação 3.12. Os valores de β<sub>is</sub> correspondem aos coeficientes gerados na seleção das variáveis.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 + \dots + \beta_n X_n \quad (3.12)$$

O aplicativo utilizado para gerar os modelos foi o SPSS 10.0. O método escolhido para a seleção das variáveis foi o *stepwise*. Após a geração do modelo a equação foi inserida no aplicativo ENVI 4.2 e por meio da ferramenta *Band Math* foi calculada a imagem “Volume de Madeira” para a área de estudo.

### **3.3.7.2.5 Validação dos resultados**

Para validar os resultados foram utilizados os 38 talhões reservados para esse fim e foi calculado o volume de madeira médio para cada talhão. Para isso os polígonos referentes a cada um dos 38 talhões foram sobrepostos na imagem “Volume de Madeira” gerada pelo modelo de regressão. Os volumes encontrados em cada talhão (volume calculado) foram comparados com os resultados fornecidos pela empresa (volume observado) e foi calculado o erro mediano.

### **3.3.7.3 Relação entre dados hiperespectrais e o volume de madeira considerando a iluminação**

Os polígonos referentes aos 88 talhões selecionados para geração do modelo foram recortados utilizando para isso as máscaras de cada classe de iluminação (iluminado, plano, pouco iluminado e escuro), gerando assim novos polígonos para cada talhão nas quatro condições de iluminação (Figura 3.15).

Para cada talhão foram extraídos os valores médios do FRB de superfície e dos índices de vegetação nas quatro classes de iluminação, gerando-se assim quatro planilhas. Os dados de volume para cada talhão foram inseridos nas planilhas e foi feita uma análise de regressão separada para cada classe de iluminação resultando em quatro imagens “Volume de Madeira”, com base na mesma metodologia descrita no item 3.3.7.2.4.

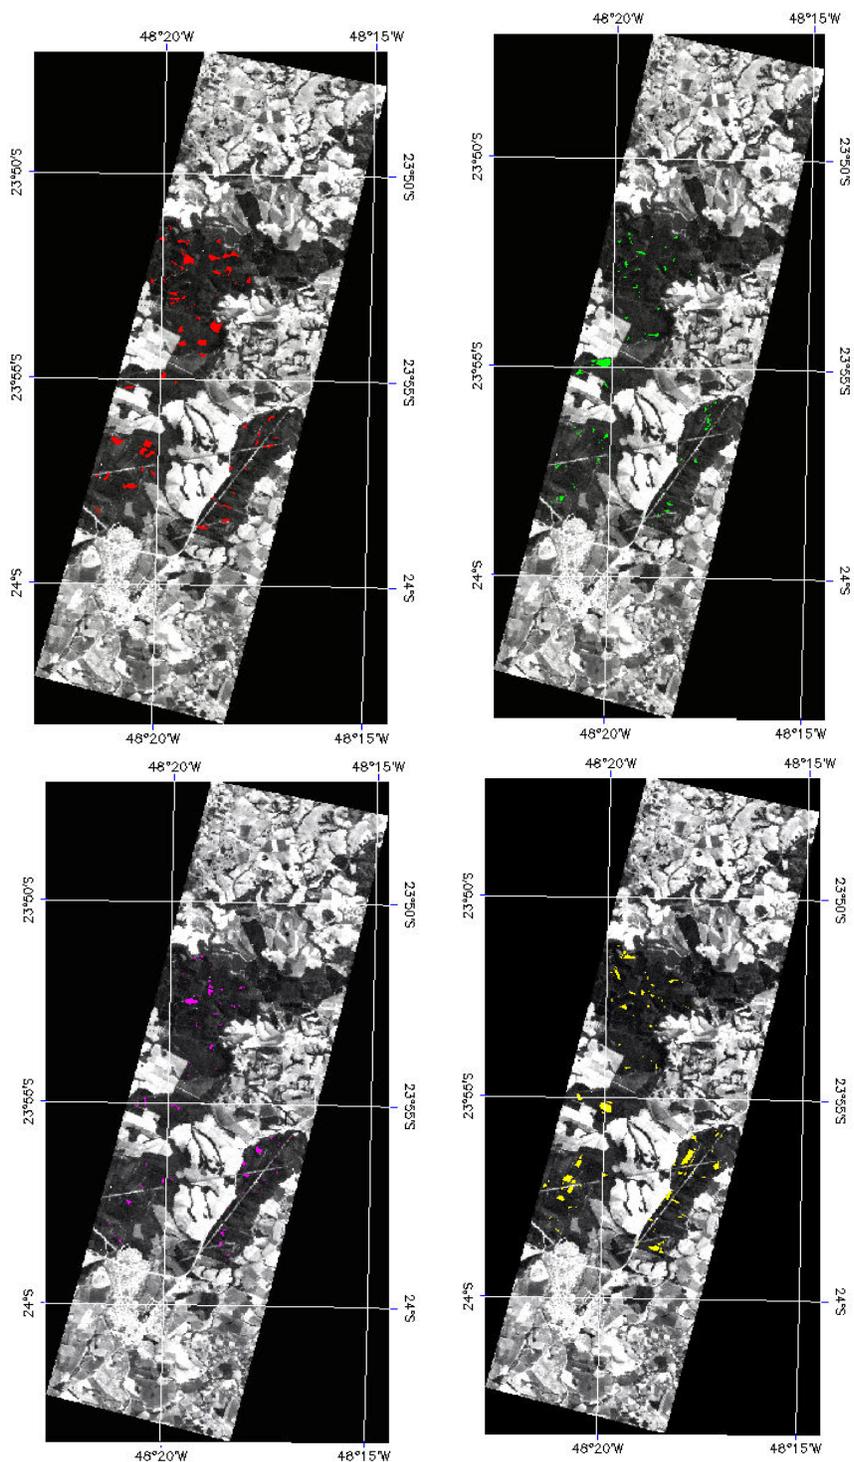


Figura 3.15 – Polígonos referentes aos 88 talhões recortados para as classe de iluminação Iluminado (vermelho), Plano (verde), Pouco Iluminado (magenta) e Escuro (amarelo).

A validação foi feita com os 38 talhões reservados e, utilizando os polígonos desses talhões, foi calculado o volume médio para cada talhão nas quatro imagens “Volume de Madeira” geradas para cada condição de iluminação (iluminado, plano, pouco iluminado e escuro). Os volumes encontrados em cada talhão (volume calculado) foram comparados com os resultados fornecidos pela empresa (volume observado) e foi calculado o erro mediano para cada condição de iluminação. O erro mediano foi utilizado em substituição ao erro médio porque o ele ocupa uma posição central na série de dados, ou seja, 50% dos valores estão abaixo dele e 50% dos valores estão posicionados acima dele, além de não ser afetado por valores extremos (erros muito altos e erros muito baixos).

## 4 RESULTADOS

### 4.1 Cálculo do fator de iluminação e definição de classes de iluminação

Para a imagem Hyperion de 20/08/2003 foram utilizados os seguintes dados de entrada na Equação 3.2, considerando o horário de passagem do satélite e as coordenadas geográficas da área de estudo que definiram o posicionamento solar e do sensor.

$\varphi_{x,y}$  = orientação das vertentes ou imagem azimute

$\varphi_s$  = azimute solar = 46,150468

$\theta_{x,y}$  = declividade ou imagem zênite

$\theta_s$  = zênite solar = 49,522817

A imagem obtida pelo cálculo do fator de iluminação continha valores variando entre 0,65 a 1,39. Os valores menores que 1 indicam vertentes voltadas para o lado oposto ao Sol, ou seja, pixels com pouca iluminação ou escuros. Valores maiores que 1 indicam vertentes voltadas para o Sol, ou seja, pixels iluminados e valores muito próximo a 1 indicam locais planos. Essa imagem foi fatiada em cinco classes arbitrariamente definidas: muito iluminado (1,242 a 1,39), iluminado (1,094 a 1,242), plano (0,946 a 1,094), pouco iluminado (0,798 a 0,946) e escuro (0,650 a 0,798). A Figura 4.1 mostra uma fração da área de estudo discretizada nas classes de iluminação estabelecidas e o posicionamento dos talhões analisados nesse estudo.

A classe de iluminação “muito iluminado” foi descartada, pois não havia amostras suficientes (número de pixels) nos talhões analisados.

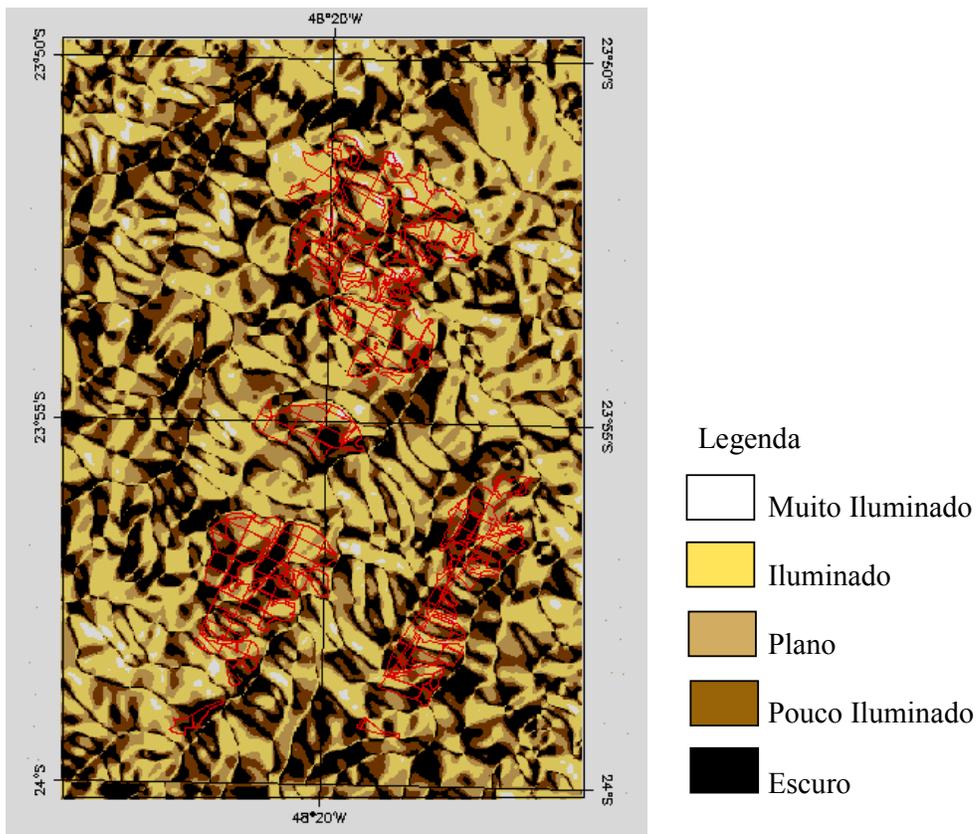


Figura 4.1 – Classes de iluminação referentes à imagem de 2003.

## 4.2 Caracterização espectral dos dosséis das espécies do gênero *Eucalyptus*

### 4.2.1 Imagens geradas pela análise das componentes principais

As componentes principais foram calculadas a partir dos autovetores gerados para cada banda, e para cada sensor, pela análise das componentes principais. Esse procedimento foi necessário para que a imagem componente principal fosse gerada baseada somente na área de interesse, ou seja, nos talhões de reflorestamento de *Eucalyptus*.

Os autovetores utilizados em cada banda para gerar a imagem componente principal dos dados do sensor Hyperion são apresentados no Apêndice A.2. As duas primeiras componentes principais apresentaram variância acumulada de 86,51%.

Nas Tabelas 4.1 e 4.2 encontram-se os autovetores utilizados para gerar as imagens componentes principais dos sensores TM e HRV. Para a imagem TM, as duas primeiras

componentes principais acumularam 94,11% da variância total dos dados originais e para a imagem HRV a variância acumulada foi de 94,87%.

TABELA 4.1 - Autovetores gerados pela análise de componente principal para a imagem TM.

Comprimento de Onda (nm)	Componente	
	PC1	PC2
570,9	0,944	0,168
661,0	0,962	-0,038
836,9	-0,529	0,845
1676,7	0,911	0,343
2215,5	0,958	0,013

TABELA 4.2 - Autovetores gerados pela análise de componente principal para a imagem HRV.

Comprimento de Onda (nm)	Componente	
	PC1	PC2
542,0	0,951	0,184
651,6	0,970	-0,031
834,9	-0,520	0,849
1627,6	0,902	0,330

As imagens resultantes desse processo foram utilizadas na etapa de classificação.

#### 4.2.2 Seleção das amostras de treinamento para o processo de classificação

A seleção das amostras de treinamento foi feita por meio da análise dos gráficos confeccionados a partir dos fatores gerados pela análise das componentes principais (PC1 x PC2) para cada amostra. Esse procedimento foi feito separadamente para cada sensor.

##### 4.2.2.1 Sensor Hyperion

Conforme mencionado no item acima, foram confeccionados gráficos a partir dos dados da PC1 e da PC2. A análise deste gráfico é similar àquela que seria realizada a partir das componentes *Brightness* e *Greenness* descritas por Kauth e Thomas (1976), ou seja, no eixo “y” destes gráficos os maiores valores estariam associados às maiores proporções de vegetação dentro de um determinado pixel, enquanto que em “x”, os maiores valores estariam associados à maior participação do solo ou neste estudo, de dosséis melhor iluminados.

Considerando o processamento dos dados Hyperion, a Figura 4.2 apresenta a distribuição dos fatores PC1 x PC2 encontrados para cada amostra e para todas as espécies presentes na área de estudo que possuíam amostras nas quatro classes de iluminação estudadas. Os números 5, 6, 1, 3 e 4 descritos no gráfico referem-se às espécies do gênero *Eucalyptus* spp. analisadas.

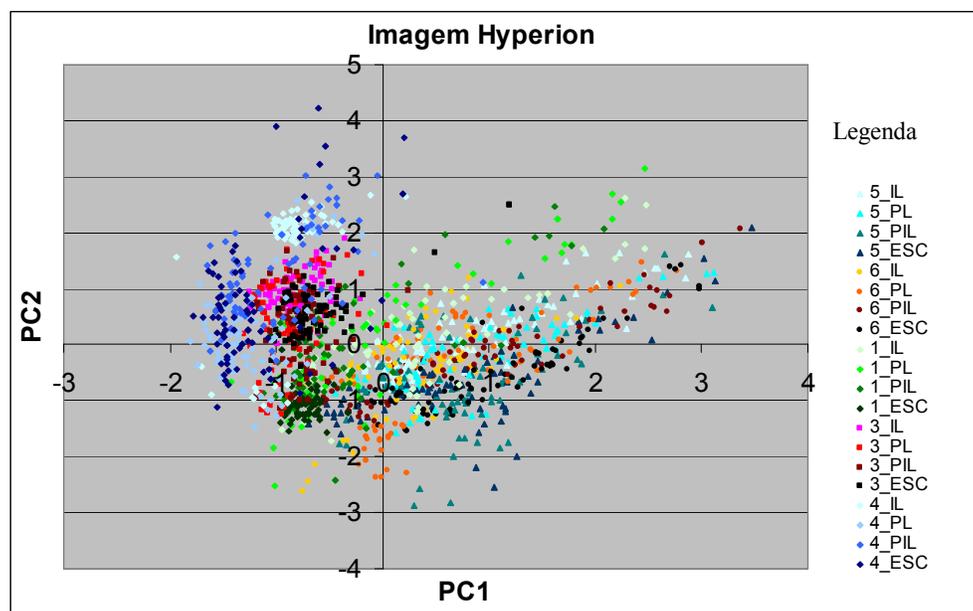


Figura 4.2 – Primeiros dois fatores referentes às componentes principais 1 e 2 para as espécies de *Eucalyptus* spp. nas quatro classes de iluminação (IL=iluminado, PL=plano, PIL=pouco iluminado, ESC=escuro), originadas da imagem Hyperion.

O posicionamento das amostras dentro desse espaço bidimensional é dependente das propriedades espectrais de cada um dos dosséis (plantios) considerados nesse estudo. Explicam esse posicionamento então as características espectrais dos elementos que compõem os dosséis como folhas, galhos, troncos e substrato (solo ou material vegetal derramado); a iluminação e a arquitetura dos indivíduos que compõem os dosséis. Evidentemente que intrínsecos a todos esses aspectos estão aqueles ligados à idade, aos espaçamentos adotados nos plantios e às espécies.

Nesse contexto e considerando ainda a conceituação já apresentada das componentes principais, espera-se que amostras dos dosséis mais velhos e com menos biomassa foliar se posicionem à direita, apresentando valores positivos no eixo x ou PC1. Já os dosséis

mais jovens e com maiores valores de biomassa foliar, tendem a se posicionar mais a esquerda e na porção superior desse gráfico, ou seja, valores negativos para o eixo x. Esse fato pode ser observado quando separam-se as mostras por idade (Figura 4.3).

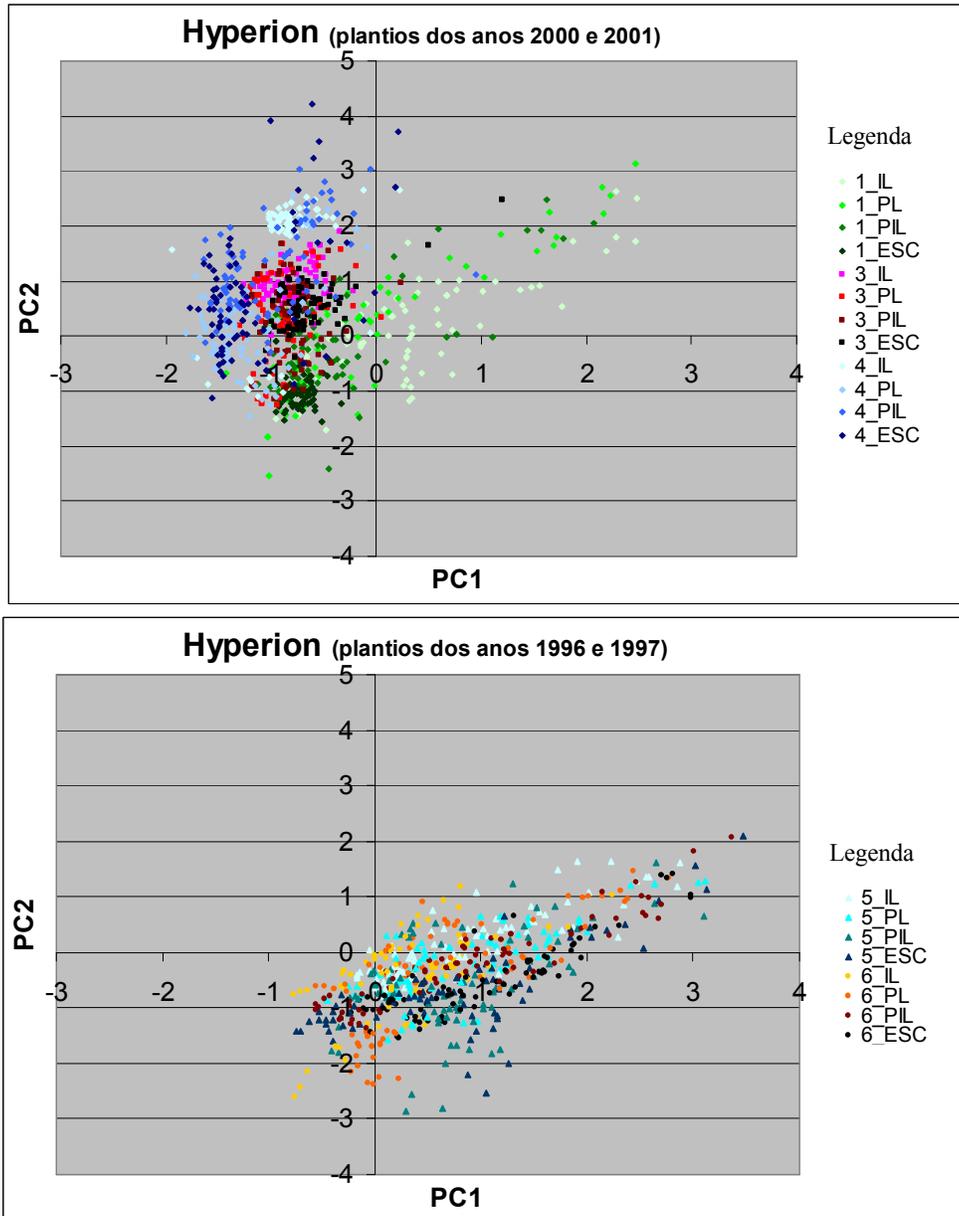


Figura 4.3 – Primeiros dois fatores referentes às componentes principais 1 e 2 (PC1 e 2) das espécies de *Eucalyptus* spp. separadas por idade para a imagem Hyperion.

Observando os gráficos apresentados acima é possível verificar que existem dois agrupamentos maiores bem definidos: um conjunto de pontos obtidos a partir das amostras de dosséis mais velhos (plantios dos anos de 1996 e 1997) e outro conjunto de pontos obtidos a partir de dosséis mais jovens (plantios dos anos de 2000 e 2001). Dentro desses dois grupos é possível definir também outros novos grupos quando a iluminação é considerada, a partir dos quais foram identificadas em que condições de iluminação as cinco espécies analisadas não se misturavam, chegando assim a um único agrupamento de pontos para cada espécie (Figura 4.4). Tais agrupamentos se referem então a dosséis com características próprias que, dentro do conjunto de dados definidos neste trabalho, acabaram se diferenciando dos demais. Cada ponto desses agrupamentos formados para cada espécie está relacionado a uma amostra, as quais serviram então como amostras de treinamento no processo de classificação.

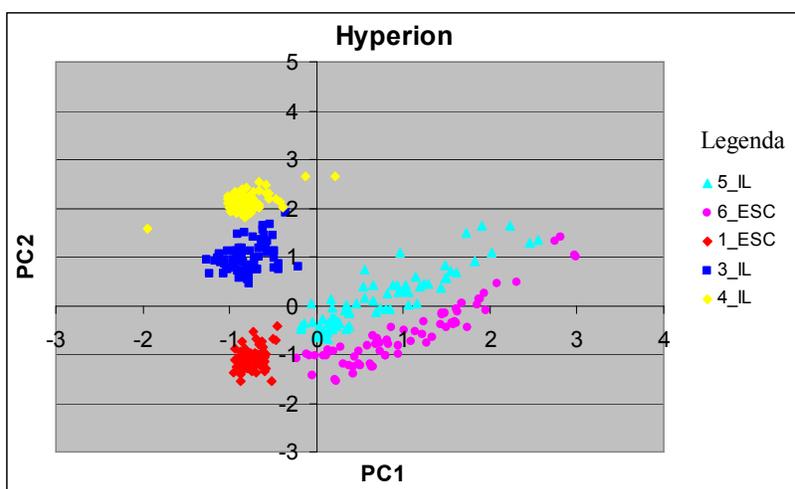


Figura 4.4 – Primeiros dois fatores referentes às componentes principais 1 e 2 (PC1 e 2) para as cinco espécies de *Eucalyptus* spp. e nas classes de iluminação selecionadas (IL=iluminados; ESC=escuros) para a imagem Hyperion.

Conforme mencionado anteriormente, a interpretação desses gráficos pode levar em consideração a distribuição *Brightness* e *Greenness*. As espécies 1, 3 e 4 foram representadas no presente trabalho por indivíduos jovens, com cerca de 3 anos de idade. Dosséis com essa idade apresentam grande quantidade de biomassa foliar e um conseqüente maior adensamento do dossel com menor penetrabilidade da luz solar.

Fazendo uma analogia entre a Figura 4.4 e a distribuição de *Brightness* e *Greenness* tem-se então as espécies 3 e 4, localizadas na parte superior do gráfico, o que indica que seus dosséis apresentam maior quantidade de cobertura vegetal. A espécie 1 está posicionada na parte inferior esquerda, local representado por pixels referentes a corpos d'água ou regiões mais sombreadas da imagem. Vale lembrar que as amostras das espécies 3 e 4 foram coletadas em locais iluminados da imagem e a espécie 1 em locais mais escuros. Isso foi feito porque o objetivo dessa etapa era o de identificar amostras de treinamento que se posicionavam em locais distintos, ou seja, que não se misturavam.

Os dosséis das espécies 5 e 6 eram mais velhos, com cerca de 6 anos de idade, verificando-se então o inverso do que foi encontrado em dosséis jovens, o seja, pouca biomassa foliar e dossel mais aberto. As amostras dessas duas espécies posicionaram-se entre os elementos água e solo, podendo indicar menor influência da biomassa foliar no FRB de superfície do dossel e uma maior participação de outros elementos como solo, folhas secas, troncos e galhos, por exemplo, além da sombra. Essas espécies, nesse estudo, apresentaram-se quase que sobrepostas, havendo diferenças sutis nos agrupamentos de pontos das amostras referentes a cada uma. Sendo assim, foram selecionadas amostras iluminadas para a espécie 5 e amostras escuras para a espécie 6, pois somente nessas condições de iluminação extremas é que elas se diferenciavam.

A figura a seguir ilustra a diferença entre indivíduos jovens e adultos nos plantios analisados. Nela pode-se observar a maior quantidade de biomassa foliar presente nos indivíduos jovens do gênero *Eucalyptus* spp. e menor nos indivíduos adultos, quando as duas fotografias das copas são comparadas.



Figura 4.5 – Fotografias da linha de plantio e da copa das árvores: espécie 3 com 3 anos de idade (acima) e espécie 6 com 7 anos de idade (abaixo).

A Figura 4.6 apresenta os espectros plotados para as cinco espécies estudadas. No primeiro gráfico (a) a iluminação não foi considerada. Isso foi feito calculando-se as médias do FRB de superfície para as amostras coletadas nas quatro classes de iluminação, ou seja, as médias das amostras das classes iluminado, plano, pouco iluminado e escuro. Já no segundo gráfico (b) as amostras de cada espécie foram provenientes somente do cálculo dos FRB de superfície médios das amostras para as classes de iluminação selecionadas na análise dos gráficos das PCs, ou seja, das amostras iluminadas para as espécies 5, 3 e 4 e amostras escuras para as espécies 6 e 1.

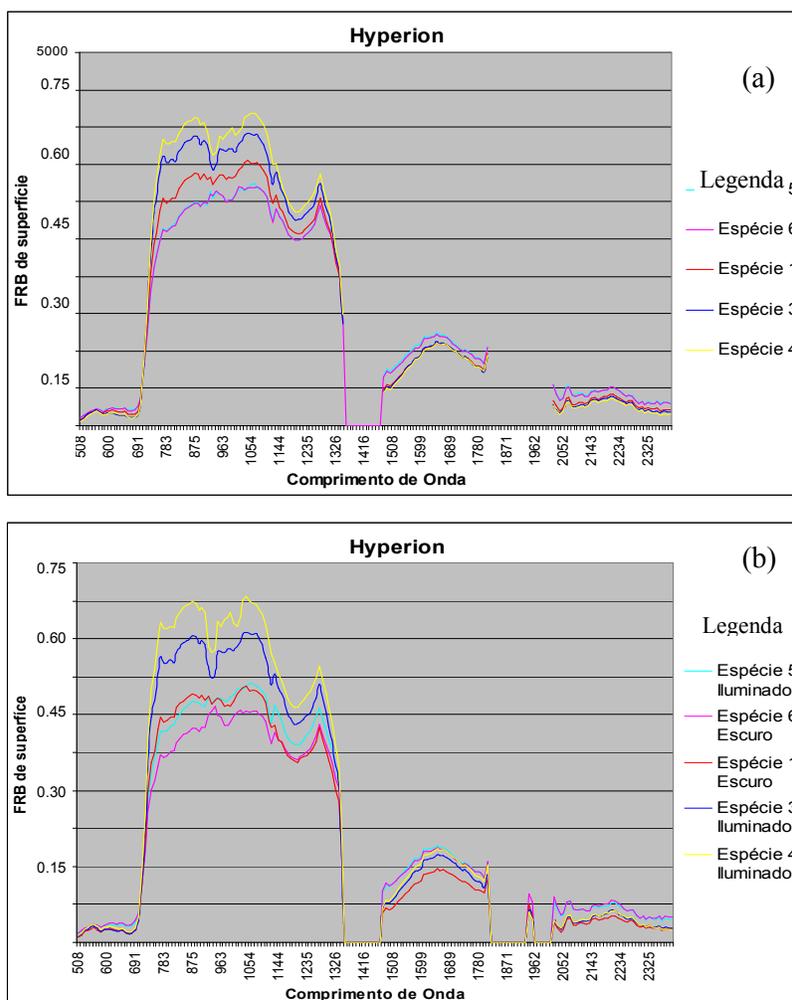


Figura 4.6 – Comparação entre os espectros médios para as espécies nas quatro classes de iluminação (acima) e os espectros para as classes de iluminação selecionadas, para a imagem Hyperion.

Primeiramente, o que se pode observar no primeiro gráfico (a) é que os indivíduos mais jovens, aqui representados pelas espécies 1, 3 e 4, apresentam reflectância maior na região do infravermelho próximo (comprimentos de onda entre 700 e 130 nm) do que as espécies mais velhas, representadas no gráfico pelas espécies 5 e 6.

Outra discussão pode ser apresentada em relação à diferenciação desses espectros do primeiro para o segundo gráfico. As espécies 5 e 6 se apresentavam sobrepostas em todo o espectro eletromagnético quando a iluminação não foi considerada e os espectros se separaram na região do infravermelho próximo (comprimentos de onda acima de 1500

nm) quando os espectros foram plotados de acordo com as classes de iluminação selecionadas pela análise das PCs (gráfico b). O espectro referente à espécie 1 se aproxima mais da espécie 5 na região do infravermelho próximo no segundo gráfico, porém ele se distancia das demais no primeiro platô do infravermelho médio (1500 a 1700 nm). As espécies 3 e 4 já se apresentavam separadas no primeiro gráfico na região do infravermelho próximo, mas os seus espectros se distanciaram ainda mais no segundo gráfico.

Quanto mais uma curva espectral de uma espécie se diferencia ou se distancia de outra, haverá evidentemente maior chance de diferenciá-las em um processo de classificação digital. Lembrando que as amostras do segundo gráfico são aquelas que serviram de amostras de treinamento na etapa de classificação.

#### **4.2.2.2 Sensor TM**

O gráfico obtido pela análise das componentes principais para o sensor TM é apresentado na Figura 4.7. Neste gráfico estão presentes amostras de todas as espécies (5, 6, 1, 3 e 4) para todas as classes de iluminação. O que se pode notar é a semelhança desse gráfico com aquele apresentado para os dados Hyperion. Esse fato pode ser explicado porque a análise das componentes principais fundamenta-se, neste caso, na reflectância espectral dos plantios florestais medida ora em bandas estreitas (Hyperion), ora em bandas mais largas (TM e HRV), dentro de uma amplitude espectral pré-estabelecida. Considerando então que está se tratando de dados dentro de uma amplitude espectral relativamente comum entre sensores, é esperado que as diferenças nos valores de reflectância (ou de FRB) identificadas entre plantios com características biofísicas distintas, sigam as mesmas tendências, quer seja quando se consideram dados hiperespectrais ou não.

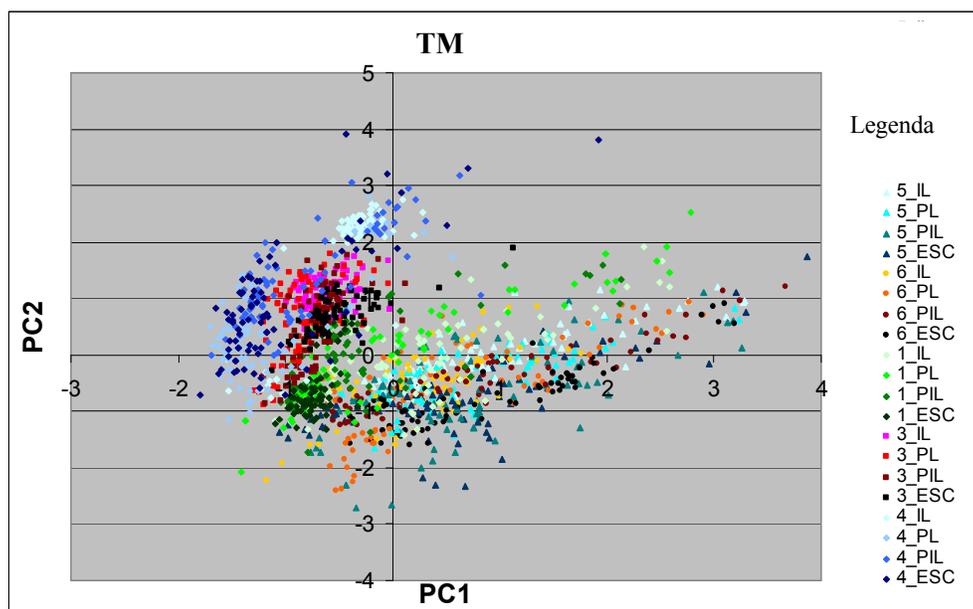


Figura 4.7 – Primeiros dois fatores referentes às componentes principais 1 e 2 para as espécies de *Eucalyptus* spp. as quatro classes de iluminação (IL=iluminado, PL=plano, PIL=pouco iluminado, ESC=escuro) originadas da imagem TM.

Analogamente ao que foi feito com os dados do sensor Hyperion, na Figura 4.8 encontram-se os gráficos das componentes principais separados por idade do plantio. A destes gráficos foi possível identificar agrupamentos de pontos ou amostras onde as espécies não se misturavam.

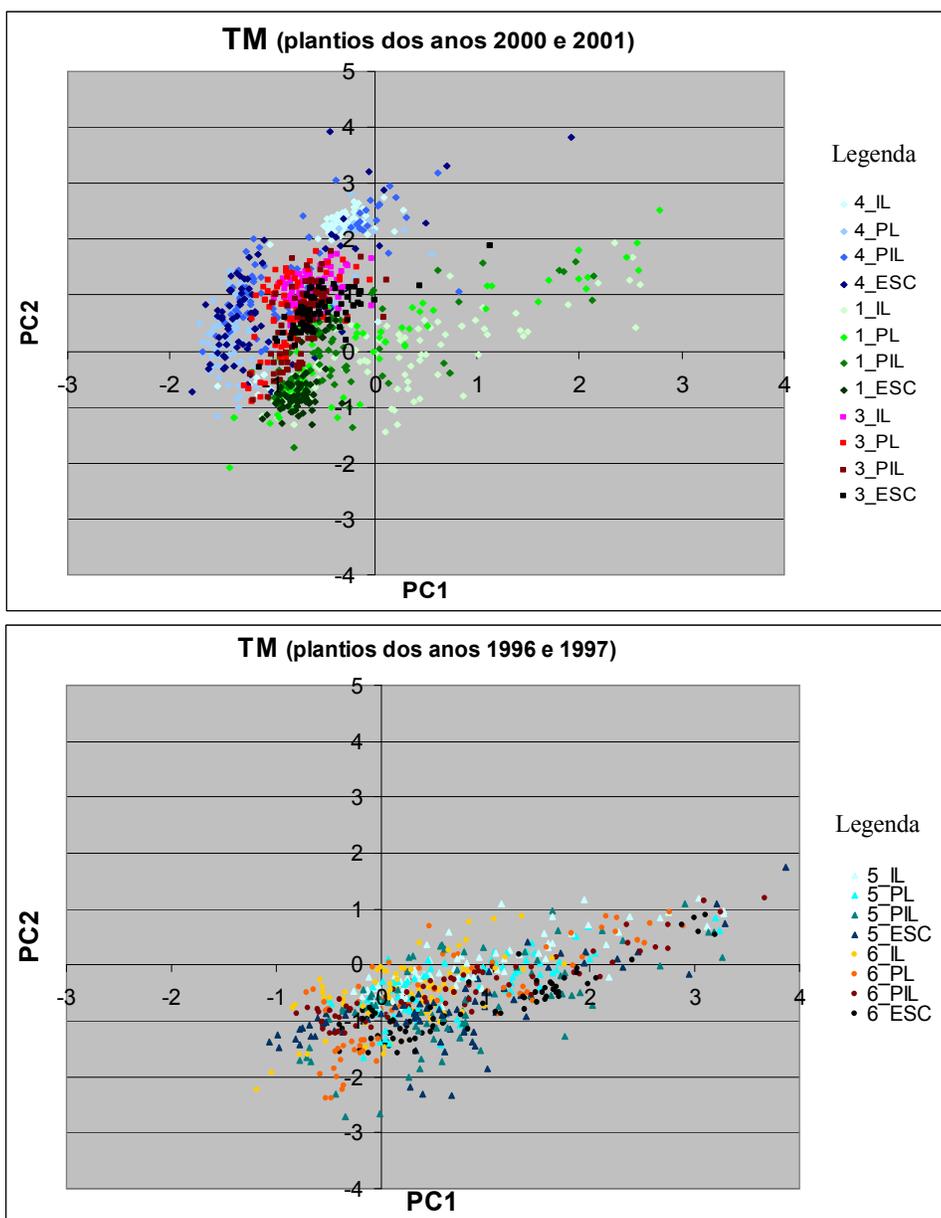


Figura 4.8 - Primeiros dois fatores referentes às componentes principais 1 e 2 das espécies de *Eucalyptus* spp. separadas por idade para a imagem TM.

O resultado dessa identificação encontra-se apresentado na Figura 4.9. Esses gráficos se assemelham ao gráfico encontrado para os dados provenientes do sensor Hyperion, valendo a mesma discussão. As amostras referentes a cada ponto dos agrupamentos abaixo foram identificadas e foram utilizadas como amostras de treinamento na etapa de classificação.

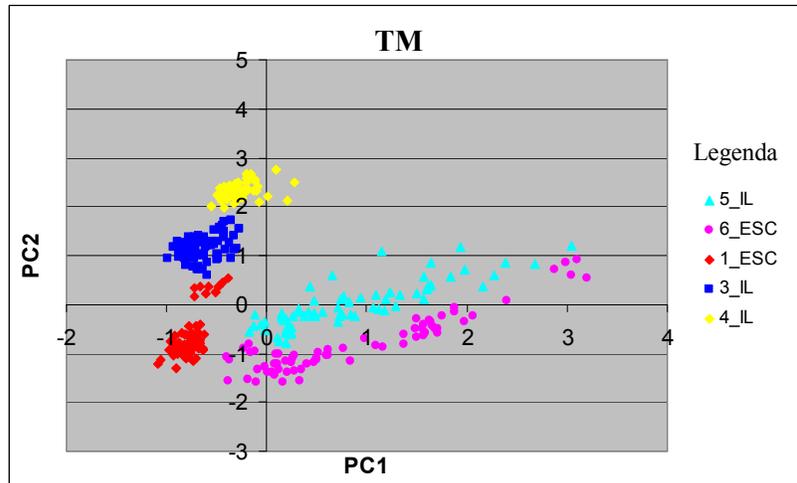


Figura 4.9 – Primeiros dois fatores referentes às componentes principais 1 e 2 das espécies de *Eucalyptus* spp. selecionadas e nas classes de iluminação selecionadas (IL=iluminados; ESC=escuros) para a imagem TM.

A Figura 4.10 apresenta os espectros plotados para as cinco espécies estudadas não considerando a iluminação e com a iluminação sendo considerada. No gráfico (a) a iluminação não foi considerada, para tanto foram calculadas as médias do FRB de superfície para as amostras coletadas nas quatro classes de iluminação, ou seja, as médias das amostras das classes iluminado, plano, pouco iluminado e escuro. Para o gráfico (b) as amostras de cada espécie foram provenientes somente do cálculo do FRB de superfície médios para as amostras nas classes de iluminação selecionadas pela análise dos gráficos das PCs, ou seja, das amostras iluminada para as espécies 5, 3 e 4 e amostras escuras para as espécies 6 e 1.

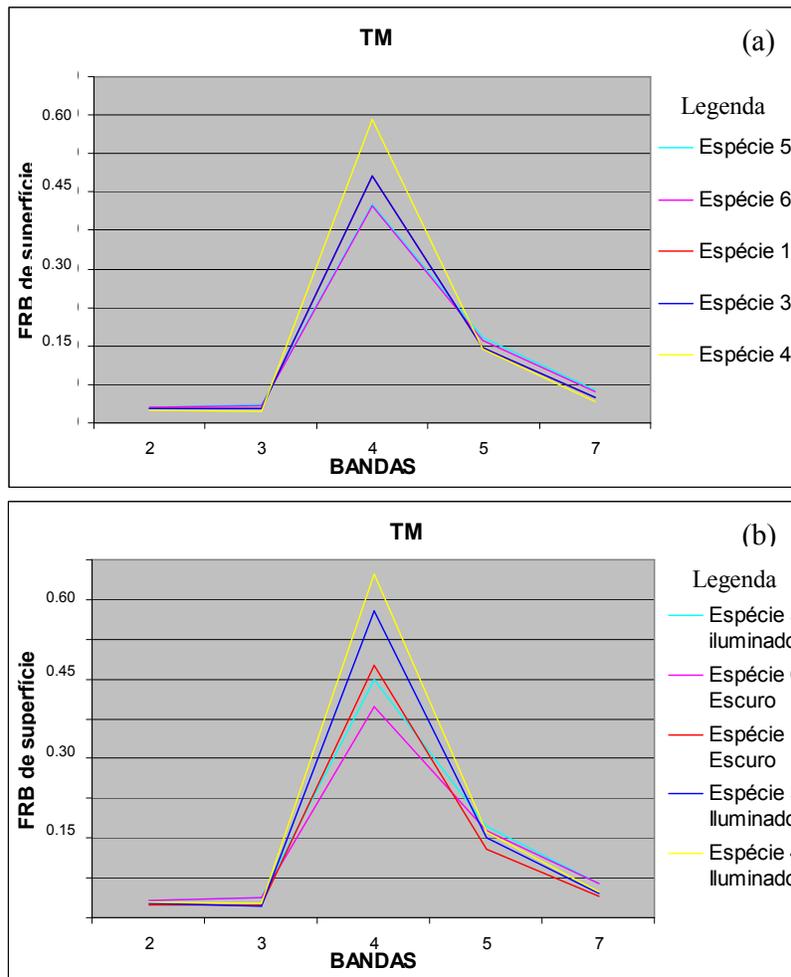


Figura 4.10 – Comparação entre os espectros médios para as espécies nas quatro classes de iluminação e os espectros para as classes de iluminação selecionadas, para a imagem TM.

Para os dados provenientes do sensor TM houve ainda uma maior sobreposição dos espectros quando a iluminação não foi considerada. Isso pode ser observado no primeiro gráfico onde os espectros referentes as espécies 5 e 6, 1 e 3 se apresentam sobrepostas nas cinco bandas analisadas. Quando as amostras foram coletadas somente nas classes de iluminação selecionadas pela análise das componentes principais, os espectros das cinco espécies ficam distinguíveis nas bandas do infravermelho próximo (836 nm) e nas bandas do infravermelho médio (1676 e 2215 nm), conforme o gráfico (b).

#### 4.2.2.3 Sensor HRV

O gráfico obtido pela análise das componentes principais para o sensor HRV é apresentado na Figura 4.11 no qual estão presentes amostras de todas as espécies (5, 6, 1, 3 e 4) em todas as classes de iluminação.

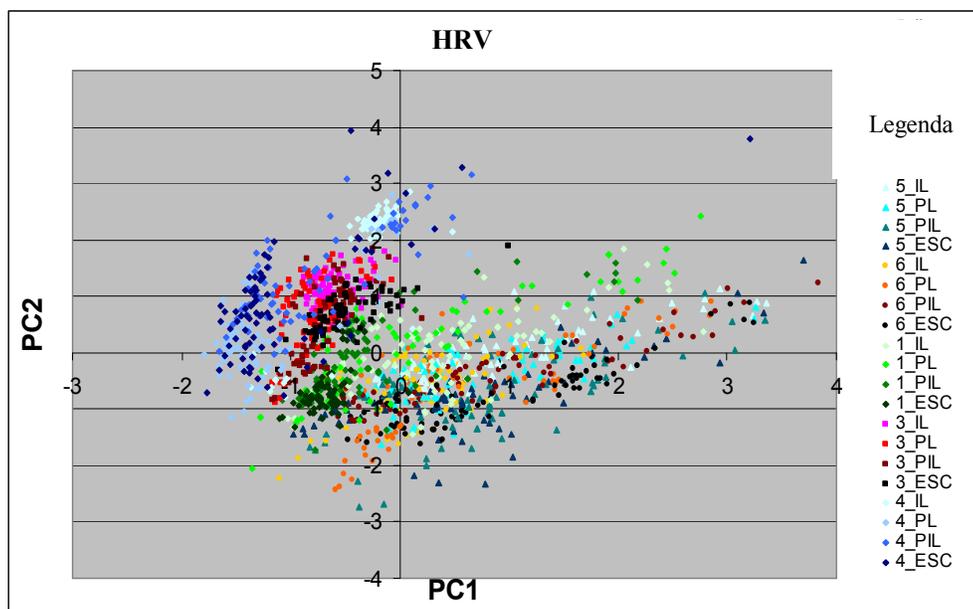


Figura 4.11 – Primeiros dois fatores referentes às componentes principais 1 e 2 para as espécies de *Eucalyptus* spp. nas quatro classes de iluminação (IL=iluminado, PL=plano, PIL=pouco iluminado, ESC=escuro) originadas da imagem HRV.

Esse gráfico se assemelha também aos gráficos definidos para os dados dos sensores Hyperion e TM.

Analogamente ao que foi feito com os resultados encontrados a partir dos dados Hyperion e TM, na Figura 4.12 encontram-se os gráficos das componentes principais separados por idade do plantio.

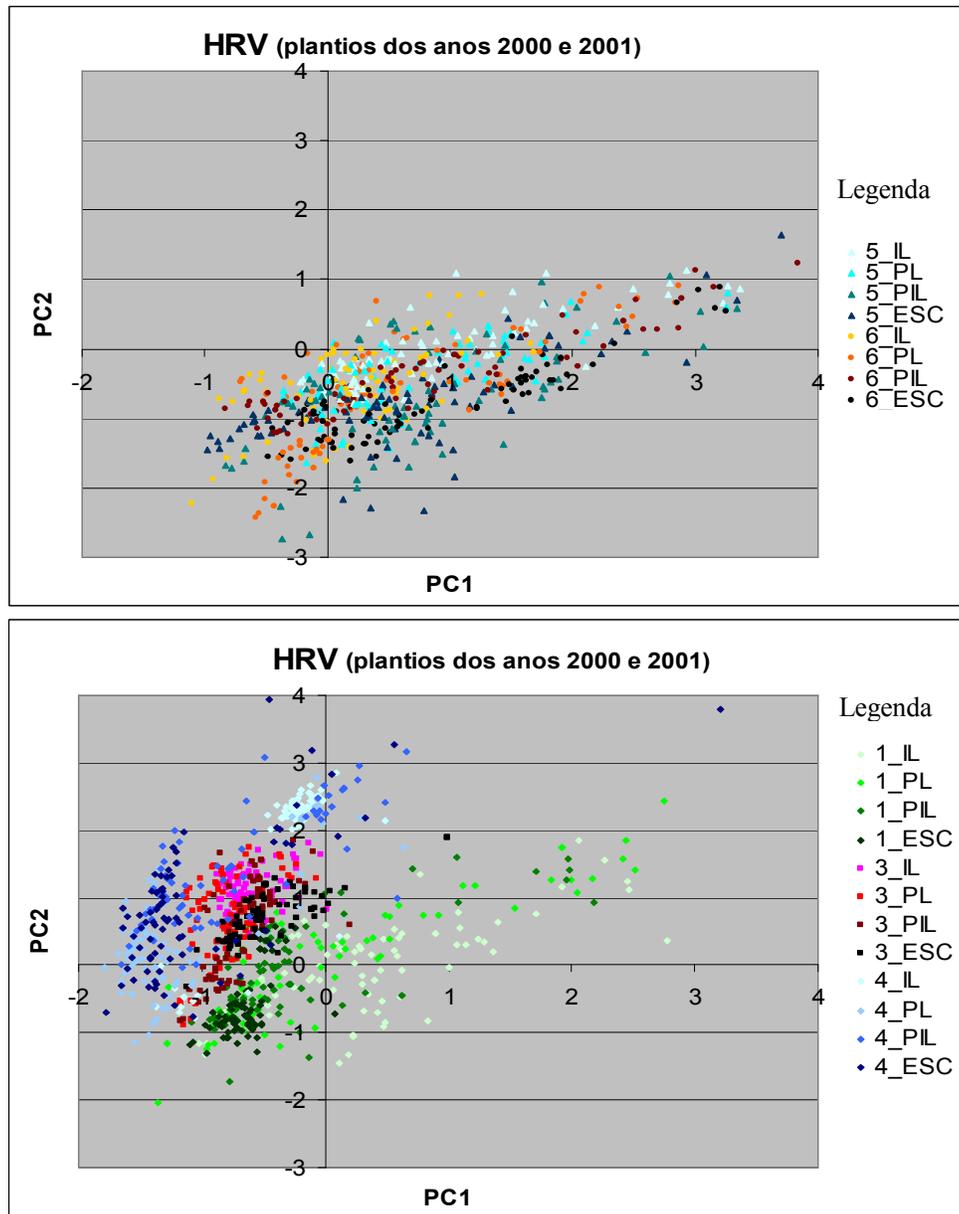


Figura 4.12 – Primeiros dois fatores referentes às componentes principais 1 e 2 das espécies de *Eucalyptus* spp. separadas por idade para a imagem HRV.

Analisando os gráficos acima foram selecionadas as classes de iluminação nas quais as espécies não se misturavam. Na Figura 4.13 encontra-se apresentada a distribuição das amostras das espécies e das classes de iluminação selecionadas. Esses gráficos também se

assemelham ao gráfico encontrado para os dados provenientes do sensor Hyperion e TM, valendo a mesma discussão.

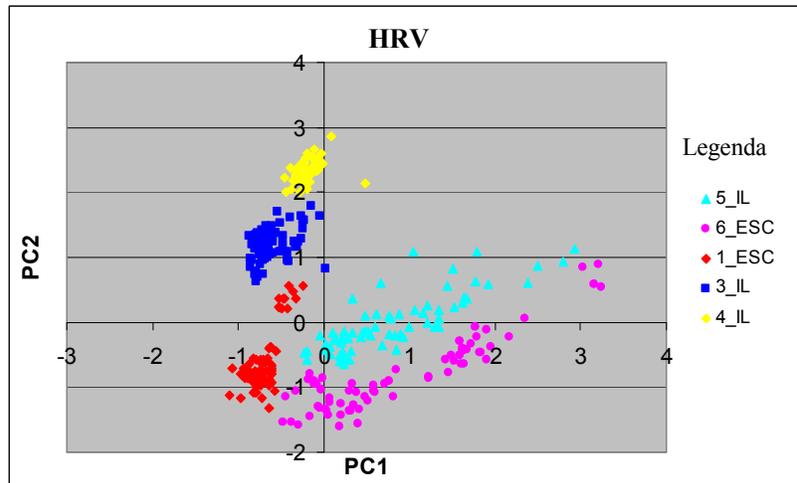


Figura 4.13 - Primeiros dois fatores referentes às componentes principais 1 e 2 das espécies de *Eucalyptus* spp. selecionadas e nas classes de iluminação selecionadas (IL=iluminados; ESC=escuros) para a imagem HRV.

A Figura 4.14 mostra a comparação entre os espectros obtidos a partir do cálculo dos valores médios do FRB de superfície para as cinco espécies sem considerar a iluminação e os espectros obtidos pelo cálculo dos valores médios do FRB de superfície para as cinco espécies somente nas classes de iluminação selecionadas pela análise das componentes principais, como foi feito para os sensores Hyperion e TM.

Para os dados do sensor SPOT houve a sobreposição dos espectros das espécies 5 e 6 para as quatro bandas analisadas quando a iluminação não foi considerada (gráfico a). Quando os espectros foram calculados a partir das amostras nas classes de iluminação selecionadas (gráfico b) esses espectros puderam ser distinguidos, especialmente nas bandas 3 (834 nm) e 4 (1627 nm).

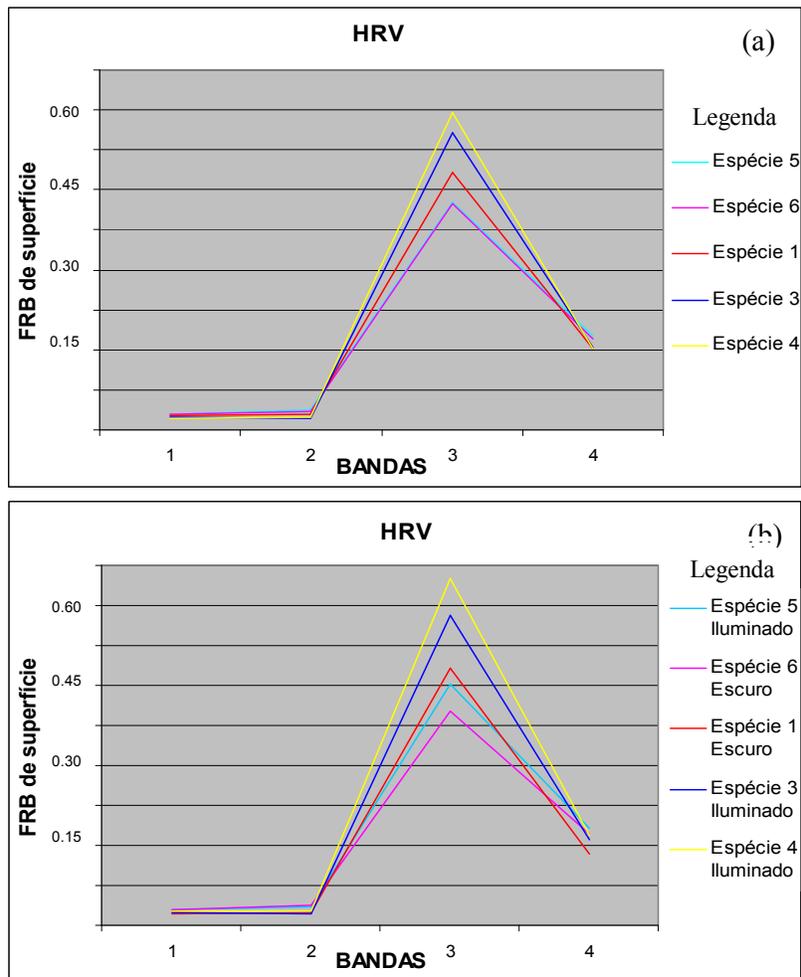
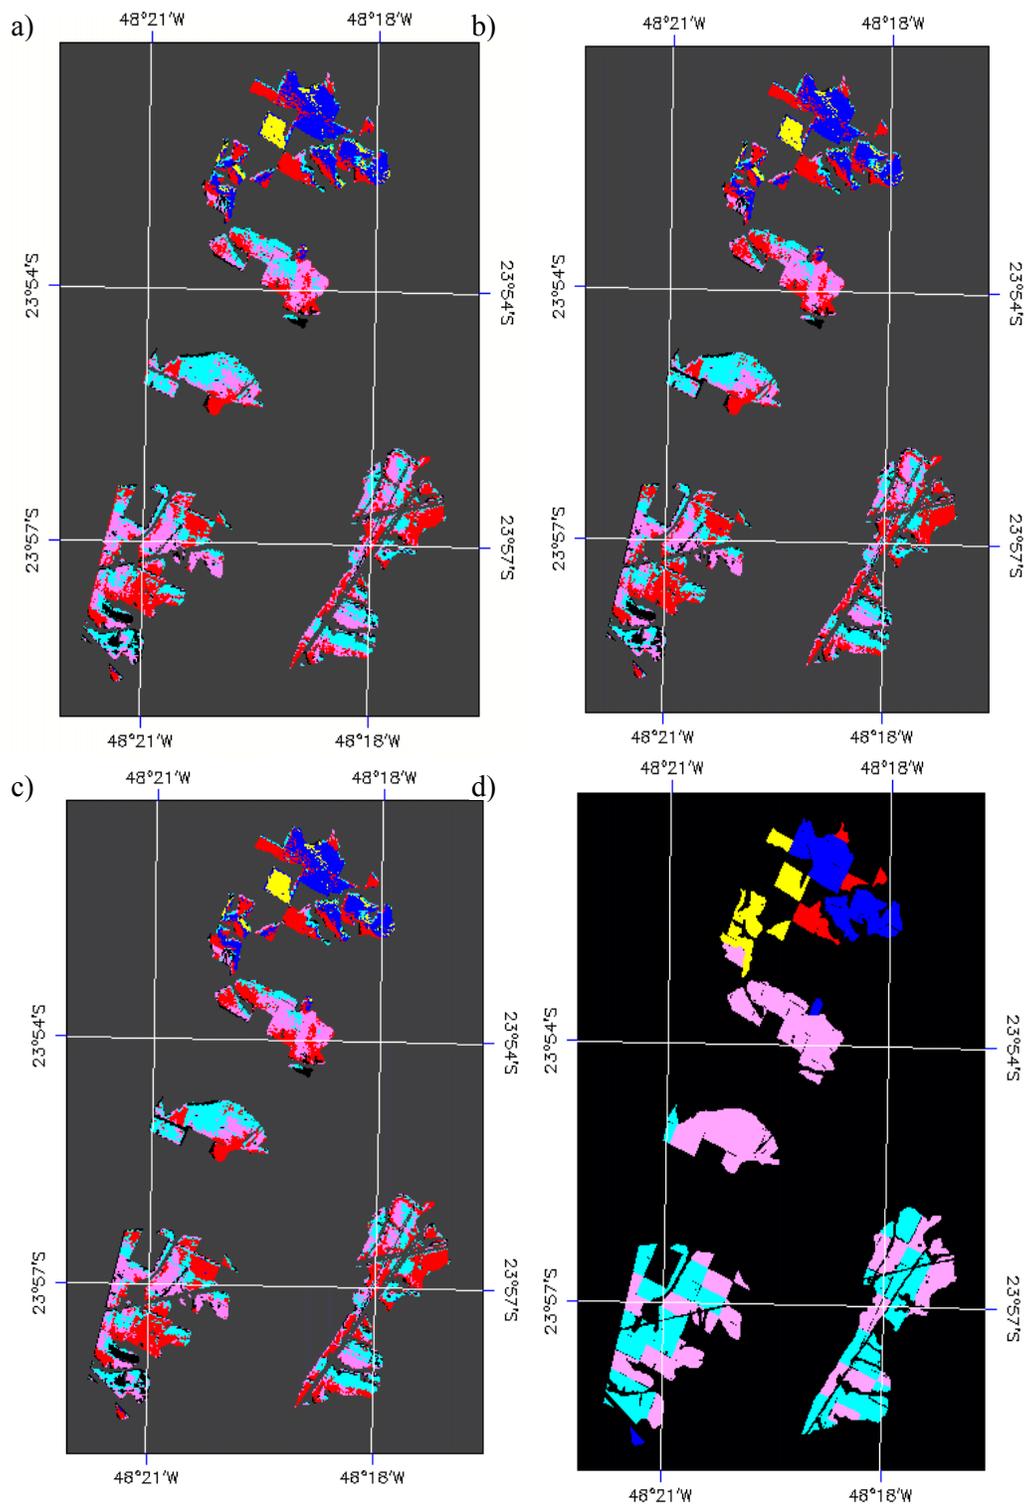


Figura 4.14 - Comparação entre os espectros médios para as espécies nas quatro classes de iluminação e os espectros para as classes de iluminação selecionadas, para a imagem HRV.

#### 4.2.3 Classificação e validação dos resultados

##### 4.2.3.1 Considerando a iluminação

A classificação foi feita utilizando as amostras selecionadas para cada espécie e para cada classe de iluminação. O classificador utilizado foi a Distância de Mahalanobis com o limiar de 1,5 para todas as classes e em todos os sensores. A Figura 4.15 ilustra a comparação entre os resultados das classificações obtidas pelos três sensores: Hyperion (a), TM (b) e HRV (c) e a verdade de campo fornecida pela empresa VCP (d).



Legenda: ■ Espécie 5 ■ Espécie 6 ■ Espécie 1 ■ Espécie 3 ■ Espécie 4  
 Figura 4.15 – Resultado da classificação para os sensores Hyperion (a), TM (b) e HRV (c) e a verdade de campo (d).

A espécie 3 foi a que melhor se distinguiu das demais apresentando valor de Kappa igual a 0,715 para os dados Hyperion, 0,731 para os dados TM e 0,727 para os dados HRV. O segundo melhor resultado foi encontrado na espécie 4 com valores de Kappa iguais a 0,653; 0,677 e 0,671 para os sensores Hyperion, TM e HRV, respectivamente (Tabela 4.3). Esses resultados eram esperados, pois nas análises dos gráficos dos espectros dessas duas espécies elas se apresentaram posicionadas separadamente das demais espécies estudadas ( s 4.6, 4.10 e 4.14).

TABELA 4.3 – Valor de Kappa para cada espécie e em cada sensor, considerando a iluminação.

Classes	Kappa		
	Hyperion	TM	HRV
Espécie 6	0,344	0,412	0,400
Espécie 5	0,133	0,189	0,195
Espécie 3	0,715	0,731	0,727
Espécie 1	0,041	0,036	0,035
Espécie 4	0,653	0,677	0,671

Goodwin et al. (2005) não conseguiu separar as espécies de *Eucalyptus* estudadas (*E. acmenoides*, *E. pilularis*, *E. saligna*, *E. paniculata*, *E. sideroxylon* e *E. deanei*). Somente uma espécie (*E. acmenoides*) foi possível individualizar em relação às demais. A área de estudo compreendia uma floresta nativa de espécies do gênero *Eucalyptus* localizada na Austrália. A identificação de cada espécie foi feita por meio de trabalho de campo e as copas individuais foram delineadas na imagem capturada pelo sensor aerotransportado CASI-2. Esse sensor possui somente 10 bandas posicionadas entre os comprimentos de onda de 450 a 850 nm e a geometria de iluminação não foi considerada.

Datt (2000), utilizando análise discriminante linear, conseguiu individualizar as 6 espécies de *Eucalyptus* que considerou em seu estudo (*E. haemastoma*, *E. piperita*, *E. gummifera*, *E. fastigata*, *E. pilularis* e *E. saligna*), mas seu trabalho foi fundamentado em valores do Fator de Reflectância Bidirecional (FRB) determinados em laboratório. As acurácias das classificações foram de 92,86% para *E. haemastoma*, 71,43 para *E. piperita*, 71,43 para *E. gummifera*, 78,57% para *E. fastigata*, 57,84% para *E. pilularis* e 50% para *E. saligna*.

Os resultados encontrados por Coops e White (2003) permitiram a distinção entre *E. saligna* e *E. pilularis* e os dados provenientes da faixa espectral em torno de 550 nm foi importante na discriminação dessas duas espécies. No presente trabalho não foi considerado um comprimento de onda específico. Todas as bandas foram estudadas conjuntamente por meio da transformação das componentes principais.

Um fato a ser considerado é que as espécies analisadas neste trabalho são provenientes de melhoramento genético, portanto, não possuem mais algumas características encontradas nas espécies originais. Entre as espécies matrizes que originaram as espécies melhoradas estão *Eucalyptus saligna*, *Eucalyptus grandis* e *Eucalyptus urophylla*. As espécies 1 e 6 apresentam as mesmas espécies matrizes, assim como as espécies 4 e 3, mostrando a grande complexidade dos dados trabalhados.

A matriz de confusão gerada a partir da comparação dos resultados encontrados na classificação realizada com dados Hyperion e a verdade de campo é apresentada na Tabela 4.4. A espécie 6 apresentou grande confusão com a espécie 5. Apesar delas não apresentaram materiais genéticos similares, a idade era igual (cerca de 6 anos) o que pode conferir características estruturais semelhantes para essas duas espécies. As curvas espectrais dessas espécies ficaram praticamente sobrepostas em todo o espectro eletromagnético (Figura 4.6 a) e só se separaram em condições de iluminação extremas, ou seja, amostras coletadas em locais iluminados para a espécie 5 e em locais escuros para a espécie 6 (Figura 4.6 b). A separação por classe de iluminação foi somente para gerar as amostras de treinamento, mas no processo de classificação foram identificados todos os locais em que essas espécies ocorriam na área de estudo, independentemente da classe de iluminação.

A espécie 6 e 5 também confundiram bastante com a espécie 1. As amostras de treinamento coletadas para a espécie 1 se referiram à parte escura da imagem, ou seja, onde o terreno era íngreme e do lado oposto à iluminação solar. Outro fato relevante é que para gerar a espécie 1 e a espécie 6, geneticamente melhoradas, foram utilizadas as mesmas matrizes.

TABELA 4.4 – Matriz de confusão para a imagem Hyperion considerando a iluminação, em pixels.

Classes		Verdade de Campo					
		Não Classificada	Espécie 6	Espécie 5	Espécie 3	Espécie 1	Espécie 4
Classificação	Não Classificada	0	1337	1333	93	31	65
	Espécie 6	0	3614	1781	34	56	52
	Espécie 5	0	2451	1807	161	96	118
	Espécie 3	0	7	11	1738	140	417
	Espécie 1	0	2667	1417	560	405	459
	Espécie 4	0	0	3	176	2	379
<b>Erro de Omissão (%)</b>		0	35,87	28,45	62,93	55,48	25,44
<b>Erro de Inclusão (%)</b>		0	65,27	39,00	75,14	7,35	67,68

Onde houve menos confusão foi entre a espécie 4 com as espécies 6, 5 e 1, onde nenhum pixel foi confundido, confusão de 3 pixels e de 2 pixels, respectivamente. O espectro dessa espécie era o que se encontrava mais distante dos demais na 4.7. Resultados semelhantes foram encontrados nas classificações utilizando os dados dos sensores TM e HRV. Suas respectivas matrizes de confusão são apresentadas nas Tabelas 4.5 e 4.6.

Para comparar os resultados alcançados pelo sensor Hyperion e os sensores simulados TM e HRV, foram cruzados os resultados obtidos pelas classificações e gerados os índices Kappa. Para os dados Hyperion versus dados TM o índice kappa foi de 0,85 e para os dados Hyperion versus HRV foi de 0,84, ficando os dois casos próximos a 1, evidenciando haver pouca diferença entre as classificação dos dados hiperespectrais e multiespectrais no presente estudo.

TABELA 4.5 - Matriz de confusão para a imagem TM considerando a iluminação, em pixels.

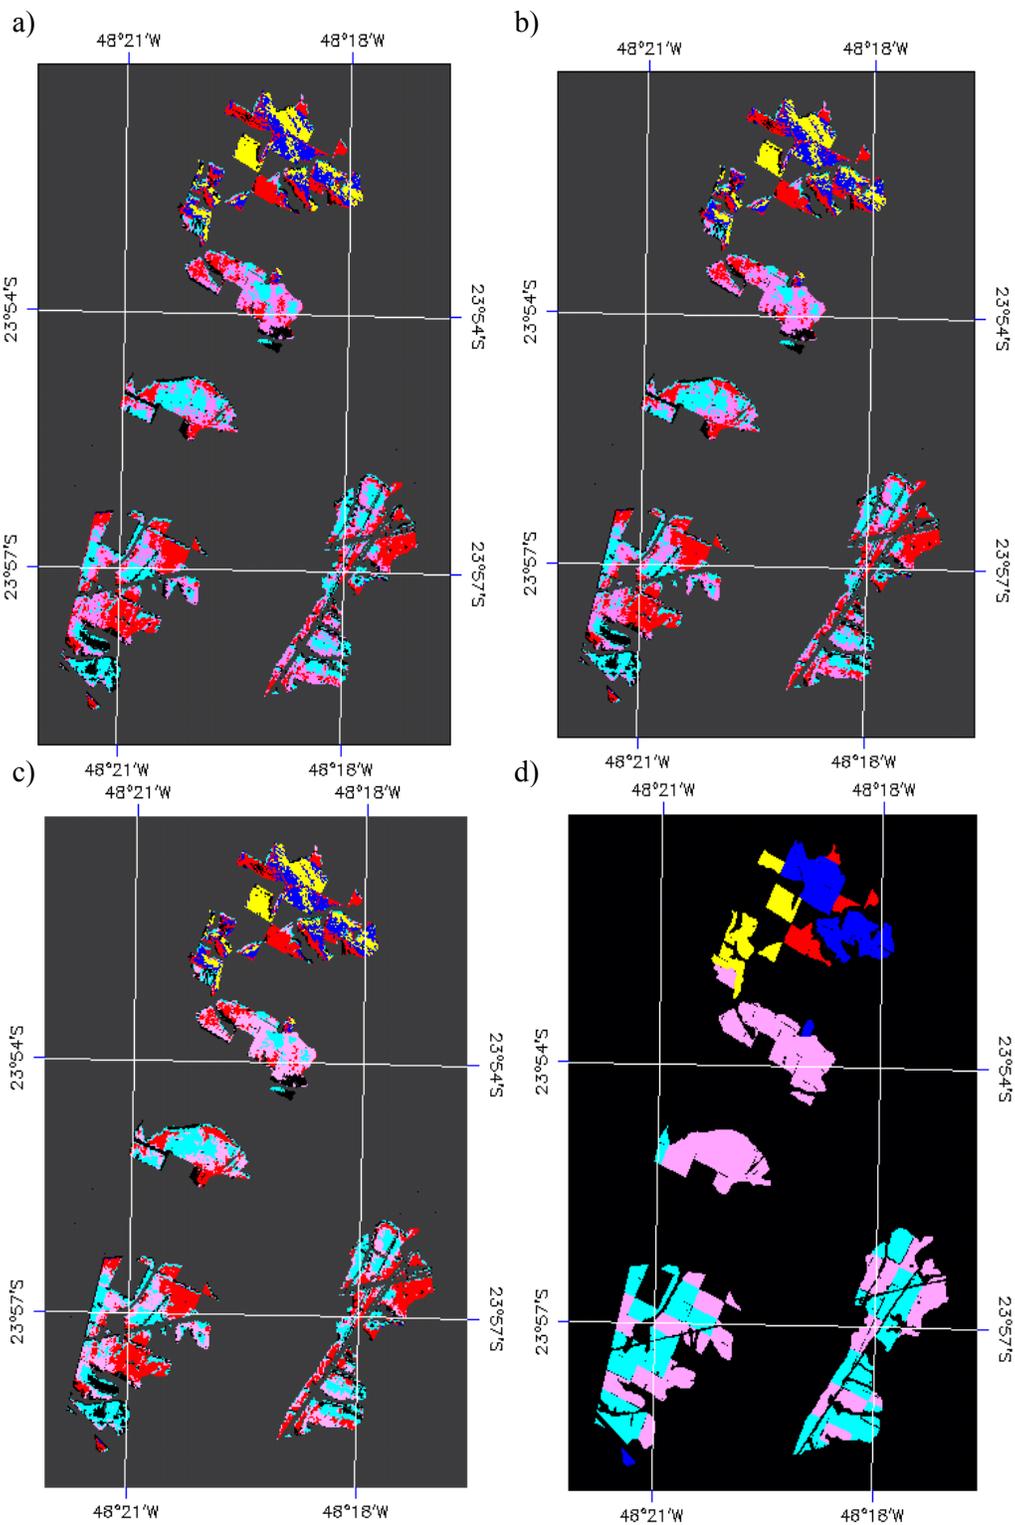
Classes		Verdade de Campo					
		Não Classificada	Espécie 6	Espécie 5	Espécie 3	Espécie 1	Espécie 4
Classificação	Não Classificada	0	1413	1414	94	32	70
	Espécie 6	0	3410	1391	38	50	64
	Espécie 5	0	2202	1930	164	102	96
	Espécie 3	0	7	4	1749	120	403
	Espécie 1	0	3044	1611	565	426	499
	Espécie 4	0	0	2	152	0	358
<b>Erro de Omissão (%)</b>		0	33,84	30,38	63,32	58,36	24,03
<b>Erro de Inclusão (%)</b>		0	68,85	42,95	76,61	6,93	69,92

TABELA 4.6 - Matriz de confusão para a imagem HRV considerando a iluminação, em pixels.

Classes		Verdade de Campo					
		Não Classificada	Espécie 6	Espécie 5	Espécie 3	Espécie 1	Espécie 4
Classificação	Não Classificada	0	1364	1372	94	30	64
	Espécie 6	0	3408	1429	38	53	65
	Espécie 5	0	2158	1916	156	90	99
	Espécie 3	0	9	7	1744	131	398
	Espécie 1	0	3137	1626	574	424	502
	Espécie 4	0	0	2	156	2	362
<b>Erro de Omissão (%)</b>		0	33,82	30,16	63,14	58,08	24,30
<b>Erro de Inclusão (%)</b>		0	68,26	43,36	76,19	6,77	69,35

#### 4.2.3.2 Desconsiderando a iluminação

A classificação foi feita utilizando as amostras de treinamento coletadas desconsiderando a iluminação, ou seja, com amostras selecionadas de forma aleatória em todas as classes de iluminação. O classificador utilizado foi o mesmo da classificação considerando a iluminação (Distância de Mahalanobis) e com o mesmo limiar (1,5) para todas as classes e em todos os sensores. A Figura 4.16 ilustra a comparação entre a verdade de campo (d) e o resultado das classificações obtidas pelos três sensores: Hyperion (a), TM (b) e HRV (c), sem considerar a iluminação.



Legenda: ■ Espécie 5 ■ Espécie 6 ■ Espécie 1 ■ Espécie 3 ■ Espécie 4  
 Figura 4.16 – Resultado da classificação para os sensores Hyperion (a), TM (b) e HRV (c) e a verdade de campo (d), desconsiderando a iluminação.

Na Tabela 4.7 estão os resultados da classificação expressos em valores de Kappa para cada espécie e para cada sensor.

TABELA 4.7 - Valor de Kappa para cada espécie e em cada sensor, desconsiderando a iluminação.

Classes	Kappa		
	Hyperion	TM	HRV
Espécie 6	0,264	0,324	0,335
Espécie 5	0,053	0,075	0,086
Espécie 3	0,655	0,668	0,670
Espécie 1	0,056	0,055	0,054
Espécie 4	0,334	0,317	0,323

Os valores de Kappa também foram maiores para as espécies 3 e 4, porém diminuíram em relação à classificação considerando a iluminação. Para a espécie 3 os valores de Kappa reduziram sensivelmente, passando de 0,731 para 0,655 (sensor Hyperion), de 0,731 para 0,668 (sensor TM) e de 0,727 para 0,670 (sensor HRV). Já para a espécie 4 essa redução foi maior ainda com valores de Kappa passando de 0,653 para 0,334; de 0,677 para 0,317 e de 0,671 para 0,323, referentes aos sensores Hyperion, TM e HRV respectivamente.

As matrizes de confusão para as classificações com dados dos sensores Hyperion, TM e HRV são apresentadas nas Tabelas 4.8, 4.9 e 4.10 respectivamente.

TABELA 4.8 - Matriz de confusão para a imagem Hyperion desconsiderando a iluminação, em pixels.

Classes		Verdade de Campo					
		Não Classificada	Espécie 6	Espécie 5	Espécie 3	Espécie 1	Espécie 4
Classificação	Não Classificada	0	1832	1552	198	49	184
	Espécie 6	0	3192	1894	46	51	47
	Espécie 5	0	2646	1426	66	47	88
	Espécie 3	0	14	17	1066	123	303
	Espécie 1	0	2392	1463	531	455	341
	Espécie 4	0	0	0	855	5	527
<b>Erro de Omissão (%)</b>		0	31,68	22,45	38,60	62,33	35,37
<b>Erro de Inclusão (%)</b>		0	61,03	33,37	69,99	8,78	38,00

Na tabela acima ocorrem as mesmas confusões entre as espécies que aconteceram quando a iluminação foi considerada, valendo-se da mesma discussão.

TABELA 4.9– Matriz de confusão para a imagem TM desconsiderando a iluminação, em pixels.

Classes		Verdade de Campo					
		Não Classificada	Espécie 6	Espécie 5	Espécie 3	Espécie 1	Espécie 4
Classificação	Não Classificada	0	1816	1578	183	48	216
	Espécie 6	0	3271	1664	40	61	58
	Espécie 5	0	2552	1490	82	51	85
	Espécie 3	0	12	7	1088	106	317
	Espécie 1	0	2425	1613	514	463	322
	Espécie 4	0	0	0	855	1	492
<b>Erro de Omisão (%)</b>		0	32,46	23,46	39,39	63,42	33,02
<b>Erro de Inclusão (%)</b>		0	64,21	34,98	71,11	8,68	36,50

TABELA 4.10 - Matriz de confusão para a imagem HRV desconsiderando a iluminação, em pixels.

Classes		Verdade de Campo					
		Não Classificada	Espécie 6	Espécie 5	Espécie 3	Espécie 1	Espécie 4
Classificação	Não Classificada	0	1842	1577	191	53	218
	Espécie 6	0	3249	1603	41	62	60
	Espécie 5	0	2492	1498	85	38	82
	Espécie 3	0	12	9	1101	106	318
	Espécie 1	0	2481	1665	508	471	320
	Espécie 4	0	0	0	836	0	492
<b>Erro de Omisão (%)</b>		0	32,24	23,58	39,86	64,52	33,02
<b>Erro de Inclusão (%)</b>		0	64,79	35,71	71,22	8,65	37,05

No trabalho de Goodwin et al. (2005) os autores também compararam amostras coletadas em toda a copa das árvores e amostras coletadas em partes iluminadas/sombreadas das copas para discriminar seis espécies de *Eucalyptus*. O valor do Kappa aumentou de 0,77 para 0,80 quando as amostras foram coletadas em diferentes condições de iluminação da copa.

Quando os resultados das classificações considerando e desconsiderando a iluminação para os três sensores os índices Kappa obtiveram os valores de 0,62 para o Hyperion, de 0,61 para o TM e de 0,62 para o HRV. Estes resultados indicam então que quando a seleção das amostras de treinamento é feita considerando a iluminação os resultados da classificação são superiores àqueles encontrados quando não se considera a iluminação.

### 4.3 Relação entre dados hiperespectrais e o volume de madeira

Dentre os 126 talhões vegetados presentes na área de estudo foram separados 88 talhões para gerar o modelo de regressão e 38 talhões para validar os resultados gerados. Nessa etapa foram utilizados os 88 polígonos dos quais foram calculados os valores médios do FRB de superfície provenientes do sensor Hyperion e os índices de vegetação médios por talhão. Esses valores foram relacionados com o volume de madeira médio para cada talhão, fornecidos pela VCP.

Esse procedimento foi feito desconsiderando e considerando a iluminação, como foi descrito na metodologia. Os resultados para os dois métodos serão apresentados separadamente.

#### 4.3.1 Estimativa do volume de madeira desconsiderando a iluminação

O método de seleção de variáveis foi a Equação (4.11), com as variáveis selecionadas pelo método *stepwise*, é apresentada a seguir.

$$Vol = 294,288 + C1326 * (-1,374) + C1253 * 0,694 + C1710 * 0,68 + C1114 * 0,251 + C1144 * (- * 0,758) + C1134 * 0,654 \quad (4.11)$$

Onde C1326 corresponde à banda no comprimento de onda de 1326 nm e assim por diante. Os índices de vegetação não participaram dessa equação. O R<sup>2</sup> ajustado para essa equação foi de 0,709. Utilizando sensores multiespectrais para estimar volume de madeira há, por exemplo, o estudo realizado por Thenkabail et al. (2003) onde foram utilizados dados do sensor IKONOS e ETM+/Landsat para espacializar o volume de madeira na área de estudo. O R<sup>2</sup> encontrado foi de 0,34 e 0,69 para sensores IKONOS e ETM+/Landsat. Já Hall et al. (2006) também realizaram um trabalho com o mesmo contexto e encontraram o R<sup>2</sup> de 0,69 para dados do sensor ETM+/Landsat. Em trabalhos realizados utilizando dados de sensores hiperespectrais na estimativa do Índice de Área Foliar (IAF), foram encontrados valores de R<sup>2</sup> = 0,80 (GONG et al., 1995), de R<sup>2</sup> variando de 0,51 a 0,86 (FERNANDES et al., 2002), e de R<sup>2</sup> variando de 0,16 a 0,67 (HU

et al., 2000), todos utilizando o sensor CASI. Utilizando dados do HyMap, Schlerf et al. (2005) encontraram  $R^2$  de 0,67 na estimativa do IAF e 0,79 na estimativa do volume. .

Os comprimentos de onda 1253, 1114, 1144 e 1134 nm estão localizados na região do infravermelho próximo, já as bandas em 1326 e 1710 nm estão localizadas na região do infravermelho médio, o que reforça a contribuição dessas regiões espectrais na predição do volume de madeira (THENKABAIL et al., 2003; LU et al., 2004; HALL et al., 2006).

Utilizando-se as amostras de validação foram comparados os dados de volume calculado, coletados diretamente na imagem volume, e os dados de volume observado, aqueles fornecidos pela empresa (Figura 4.17).

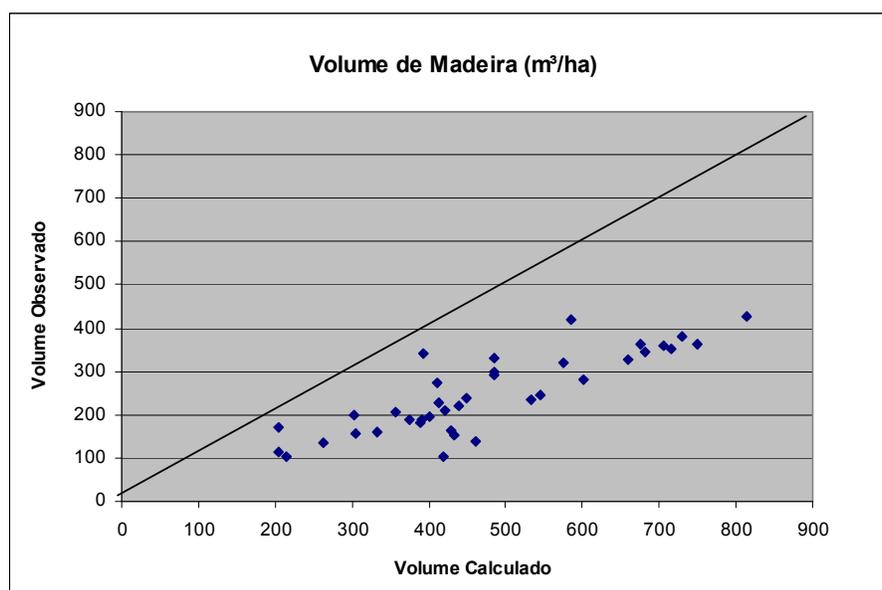


Figura 4.17– Volume de madeira calculado e volume observado para os dados do sensor Hyperion.

O erro mediano foi de + 209  $m^3$  por hectare, superestimando o volume real da área de estudo. Esse erro é alto e pode ser explicado pelo modo em que as variáveis foram coletadas, onde o talhão inteiro foi utilizado para o cálculo do FRB de superfície média e dos índices de vegetação, englobando diferentes condições de iluminação. Uma interpretação prática para isso seria a escala de trabalho em que o modelo foi desenvolvido, pois quando se calcula o FRB de superfície média para grandes áreas,

locais com diferentes geometrias de iluminação são considerados iguais, reduzindo assim a acurácia dos resultados (FRANKLIN, 2001).

#### 4.3.2 Estimativa do volume de madeira considerando a iluminação

Foram geradas equações separadas para cada classe de iluminação e foram geradas então quatro imagens volume. A validação dos resultados foi feita separadamente para que fossem identificadas as classes de iluminação com a maior correlação com o volume.

##### 4.3.2.1 Classe iluminado

De posse das amostras separadas para a geração do modelo (talhões) recortadas para a classe “iluminado” foi originado o modelo abaixo (Equação 4.12) utilizando o método *stepwise*.

$$Vol = -670,521 + VOG1 * 196,969 + C1336 * (-0,279) + C1710 * 3,44 + C1760 * (-3,253) + ARI1 * 69707,919 + C559 * 0,795 \quad (4.12)$$

O R<sup>2</sup> ajustado foi de 0,621. Nessa condição de iluminação foram contemplados índices de vegetação no modelo. O primeiro deles é o VOG1 (*Vogelmann Red Edge Index 1*), o qual é aplicado em estudos da fenologia da vegetação e modelagem da produtividade da vegetação. É sensível à concentração de clorofila na folhagem, área foliar do dossel e quantidade de água nas folhas. Os comprimentos de onda 740 e 720 nm estão presentes na sua fórmula os quais estão localizados na borda vermelha do espectro da vegetação (VOGELMANN et al., 1993).

Outro índice presente no modelo é o ARI1 (*Anthocyanin Reflectance Index 1*), o qual é sensível ao conteúdo de clorofila nas folhas e as alterações nesse índice indicam incremento de folhas jovens no dossel ou folhas senescentes. Na sua fórmula estão comprimentos de onda 550 e 700 nm (GITELSON et al., 2001).

Os comprimentos de onda 1336, 1710 e 1760 nm estão presentes no modelo e se posicionam na região do infravermelho médio. Entrou também o comprimento de onda 559 nm, referente à região do visível.

A Figura 4.18 mostra os resultados encontrados nos talhões de validação para a imagem volume calculada pela Equação 4.12 e os dados de volume fornecidos pela empresa. Nesse gráfico podemos observar um resultado superior ao encontrado quando a iluminação não foi considerada.

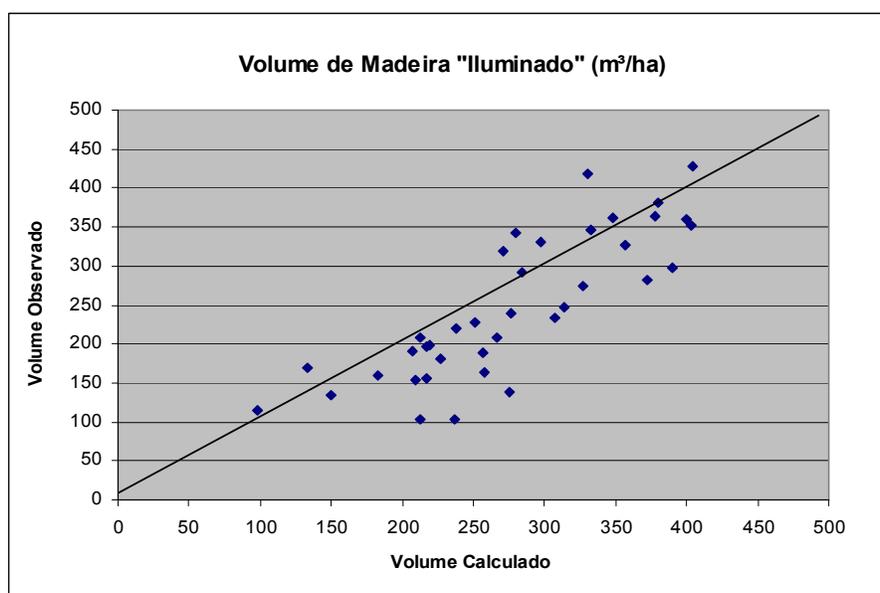


Figura 4.18 - Volume de madeira calculado e volume observado para os dados do sensor Hyperion, utilizando as amostras iluminadas.

O erro mediano foi de + 22,61 m<sup>3</sup> por hectare, resultado melhor do que o que foi encontrado na etapa anterior, desconsiderando a iluminação, o que reforça a discussão feita por Franklin (2001). Hall et al. (2006) encontraram um erro de 70,3 m<sup>3</sup>/ha utilizando dados do sensor ETM+ na estimativa de volume em uma floresta temperada. Mäkelä e Pekkarinen (2004) encontraram um erro de 71 a 80 m<sup>3</sup>/ha utilizando dados TM.

#### 4.3.2.2 Classe Plano

Utilizando as amostras selecionadas para a geração dos modelos recortadas para a classe “plano” foi construído o modelo abaixo (Equação 4.13). O método de seleção das variáveis utilizado também foi o *stepwise*.

$$Vol = 558,121 + C1114 * 0,157 + C1326 * (-1,056) + C1235 * 1,461 + C1276 * (-0,862) + C1810 * 0,296 \quad (4.13)$$

Nessa equação nenhum índice de vegetação entrou no modelo. Somente bandas posicionadas na região do infravermelho próximo (1114, 1235 e 1276 nm) e médio (1810 nm) somente contribuíram para explicar a variável volume. O  $R^2$  ajustado foi de 0,662.

A Figura 4.19 apresenta os resultados obtidos com a Equação 4.13 e compara com a verdade fornecida pela empresa. O erro mediano foi de + 20,92 m<sup>3</sup> por hectare.

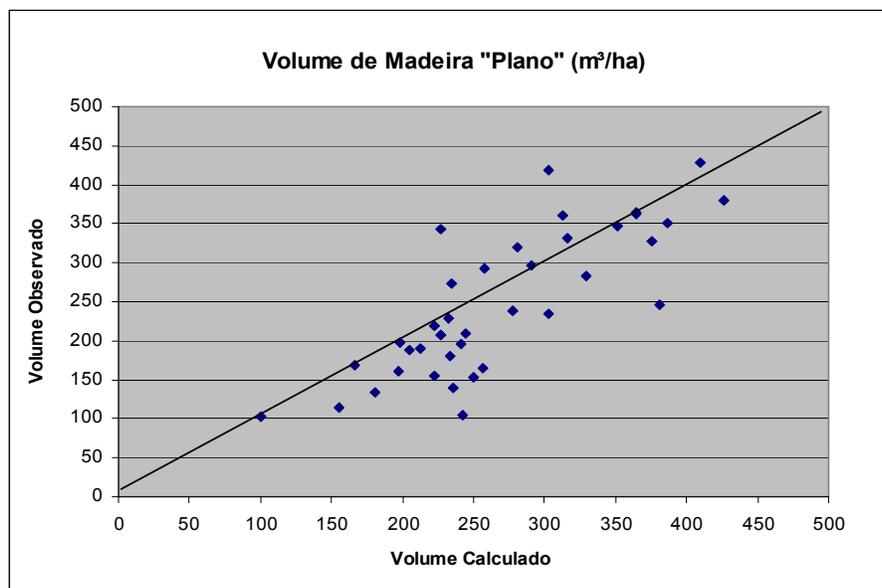


Figura 4.19 - Volume de madeira calculado e volume observado para os dados do sensor Hyperion, utilizando as amostras planas.

#### 4.3.2.3 Classe Pouco Iluminado

De posse dos talhões referentes às amostras selecionadas para gerar o modelo e recortados para a classe “pouco iluminado” foi obtido o modelo abaixo (Equação 4.14). Também foi utilizado o método *stepwise* de seleção das variáveis.

$$Vol = -816,459 + C1306 * (-1,056) + C1215 * 0,532 + MSI * 1488,912 + C824 * 0,369 + NDVI * 929,989 \quad (4.14)$$

Nessa equação novamente apareceram índices de vegetação. O primeiro deles é o MSI (*Moisture Stress Index*) o qual é sensível ao aumento do conteúdo de água foliar. É utilizado em análise de estresse do dossel, predição e modelagem de produtividade,

análise da condição do perigo de fogo e estudos fisiológicos de ecossistemas (Hunt Jr. e Rock, 1989).

O NDVI (*Normalized Difference Vegetation Index*) é um dos índices de vegetação mais antigos que existem e sua formulação é baseada na diferença da reflectância da vegetação na região do vermelho e do infravermelho próximo (ROUSE et al., 1973). Esse índice também entrou em modelos para predição de volume nos trabalhos de Foody et al. (2003) e Lu et al. (2004).

Entraram no modelo também os comprimentos de onda na região do infravermelho próximo (824 nm), infravermelho próximo (1215 nm) e infravermelho médio (1306 nm). O  $R^2$  ajustado foi de 0,589 que, embora seja o menor encontrado até agora, foi o que apresentou os melhores resultados com erro mediano de + 3,29 m<sup>3</sup> por hectare na validação dos resultados. A Figura 4.20 compara os resultados obtidos pela Equação 4.14 e a verdade fornecida pela empresa.

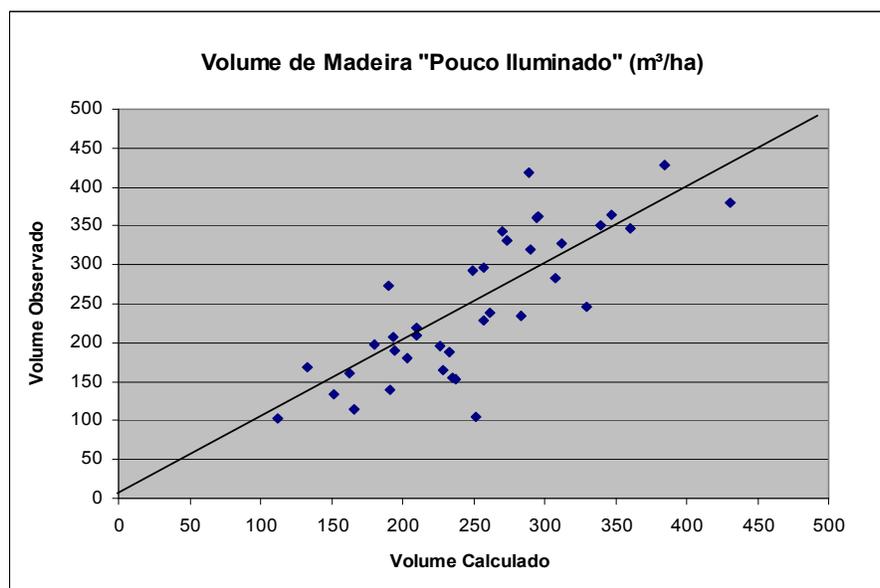


Figura 4.20 - Volume de madeira calculado e volume observado para os dados do sensor Hyperion, utilizando as amostras pouco iluminadas.

#### 4.3.2.4 Classe Escuro

Com as amostras selecionadas para a geração do modelo recortadas para a classe “escuro” foi originado o modelo abaixo (Equação 4.15), utilizando o método stepwise.

$$Vol = -664,1 + C1669 * 2,114 + C963 * 0,916 + C1790 * (-1,604) + PRI * (-876,687) + C1316 * (-1,123) + C953 * (-0,363) + WBI * 676,37$$

(4.15)

No modelo gerado para as amostras posicionadas em locais escuros da imagem entraram dois índices de vegetação: PRI e WBI. O *Photochemical Reflectance Index* (PRI) é um índice sensível às mudanças nos pigmentos carotenóide (principalmente a xantofila) na folhagem. Esses pigmentos são indicativos da eficiência do uso da luz fotossinteticamente ativa e é utilizado em estudos de estresse de produtividade da vegetação (GAMON et al., 1992). O *Water Band Index* (WBI) é sensível ao conteúdo de água no dossel e é utilizado na análise de estresse no dossel, predição e modelagem da produtividade, estudos fisiológicos de ecossistemas e indicativo de perigo de fogo (PENUELAS et al., 1996).

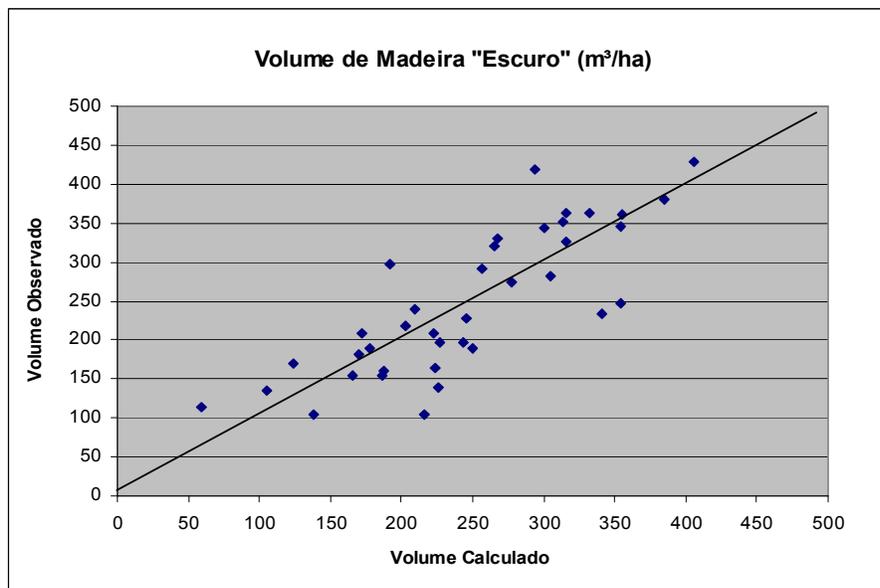


Figura 4.21 - Volume de madeira calculado e volume observado para os dados do sensor Hyperion, utilizando as amostras escuras

Foram incluídos também no modelo comprimentos de onda 953 e 963 nm (infravermelho próximo) e 1669, 1790 e 1316 (infravermelho médio). O  $R^2$  ajustado foi de 0,704. A figura acima (Figura 4.21) apresenta o volume de madeira calculado e volume observado. O Erro Mediano foi de  $-7,787 \text{ m}^3$ .

Um estudo foi feito somente para fins de comparação onde as imagens simuladas dos sensores TM e HRV foram utilizadas para espacializar o volume de madeira. Foi utilizado o mesmo procedimento descrito para a imagem Hyperion e foram calculados dois índices de vegetação: o NDVI e o índice da Razão Simples, aqui denominado de Razão, o qual simplesmente divide a banda do infravermelho próximo pela banda do vermelho.

Para a imagem TM a equação sem considerar a iluminação foi a seguinte:

$$Vol = -116,776 + Razão * 16,568 + B2 * 0,576 \quad (4.16)$$

No processo de validação obteve-se o erro mediano de -19,04.

Quando a iluminação foi considerada foram obtidas as seguintes equações de volume:

$$\text{Classe iluminado: } Vol = -46,237 + Razão * 14,921 + B7 * 0,204 \quad (4.17)$$

$$\text{Classe Plano: } Vol = 109,041 + Razão * 10,309 \quad (4.18)$$

$$\text{Classe Pouco Iluminado: } Vol = -10,395 + Razão * 13,008 + B2 * 0,364 \quad (4.19)$$

$$\text{Classe Escuro: } Vol = 15,944 + Razão * 12,483 + B7 * 0,143 \quad (4.20)$$

Os erros medianos encontrados no processo de validação foram de -30,61 m<sup>3</sup> para a classe iluminado, -25,88 m<sup>3</sup> para a classe plano, -28,59 m<sup>3</sup> para a classe pouco iluminado e -31,79 m<sup>3</sup> para a classe escuro.

Para a imagem HRV a equação sem considerar a iluminação foi a seguinte:

$$Vol = -128,156 + Razão * 18,435 + B2 * 0,457 \quad (4.21)$$

No processo de validação obteve-se o erro mediano de -15,12.

Já considerando a iluminação as seguintes equações de volume foram obtidas:

$$\text{Classe iluminado: } Vol = 439,487 + Razão * 15,528 + NDVI * (-477,211) \quad (4.22)$$

$$\text{Classe Plano: } Vol = 104,276 + Raz\tilde{a}o * 10,654 \quad (4.23)$$

$$\text{Classe Pouco Iluminado: } Vol = -16,834 + Raz\tilde{a}o * 13,462 + B1 * 0,404 \quad (4.24)$$

$$\text{Classe Escuro: } Vol = 348,513 + Raz\tilde{a}o * 13,527 - NDVI * (-338,405) \quad (4.25)$$

No processo de validação foram encontrados os erros medianos de -28,52 m<sup>3</sup>; -26,11 m<sup>3</sup>; -28,65 m<sup>3</sup> e -27,34 m<sup>3</sup> para as classes iluminado, plano, pouco iluminado e escuro, respectivamente.

O que se observa é que os resultados obtidos utilizando dados multiespectrais não responderam como se esperava em relação às diferentes classes de iluminação. As bandas largas também podem ter contribuído para esse resultado.



## 5 CONCLUSÕES

Pelos resultados aqui alcançados conclui-se que:

- Na etapa de classificação, houve um aumento na exatidão do mapeamento em relação à verdade de campo quando as amostras de treinamento foram coletadas considerando a iluminação comparada aos resultados obtidos quando as amostras de treinamento foram coletadas sem que a iluminação fosse considerada;
- A geometria de iluminação exerce influência no processo de espacialização do volume de madeira utilizando dados de um sensor remoto. O erro mediano encontrado na etapa de validação dos resultados foi maior quando a iluminação não foi considerada para a coleta das amostras de geração do modelo. Quando a iluminação foi considerada e as amostras foram coletadas em diferentes condições de iluminação, o erro mediano baixou e o melhor resultado foi alcançado na classe de iluminação “pouco iluminado”;
- Na espacialização do volume de madeira, os resultados encontrados para o sensor hiperespectral Hyperion foram superiores aos encontrados para os sensores remotos multiespectrais simulados;
- Os índices de vegetação calculados a partir de bandas estreitas estavam presentes em três das cinco equações de espacialização do volume de madeira a partir de dados do sensor Hyperion, confirmando a importância desses índices nesse tipo de estudo.



## 6 REFERÊNCIAS BIBLIOGRÁFICAS

- AMBIENTE BRASIL. Florestal, **Inventário florestal e manejo de reflorestamento**. Disponível em: <http://www.ambientebrasil.com.br>. Acesso em 08 out 2005.
- ASNER, G.P. Biophysical and biochemical sources of variability in canopy reflectance. **Remote Sensing of Environment**, n. 64, p. 234-253, 1998.
- ARAI, E.; FREITAS, R.M.; ANDERSON, L.O.; SHIMABUKURO, Y. E. Análise radiométrica de imagem MOD09 em 16bits e 8bits. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 12, 16 a 21 abr. 2005, Goiânia. **Anais...São José dos Campos: INPE, 2005. Artigos. p. 3983-3990. ISBN 85-17-00018-8. On-line. Disponível em: <http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.21.12.49/doc/541.pdf>. Acesso em 15 mai. 2008.**
- BACHA, C.J.C.; BARROS, A.L.M. Reflorestamento no Brasil: evolução recente e perspectivas para o futuro. **Scientia Forestalis**, n. 66, p. 191-203, 2004.
- BECK, R. **EO-1 User Guide**. 2003, 74 p. On line, disponível em: <http://eo1.usgs.gov/documents.php>). Acesso em: 02 mai 2006.
- BEST, R.G.; HARLAN, J.C. Spectral estimation of green leaf area index of oats. **Remote Sensing of Environment**, v. 17, p. 27-36, 1985.
- BOLFE, E.L.; FONSECA, E.L.; PEREIRA, R.S.; MADRUGA, P.R.A. Verificação da exatidão em classificação digital de povoamentos florestais em imagem orbital mediante três índices. In: Simpósio Brasileiro de Sensoriamento Remoto, 11, 5-10 abr. 2003. Belo Horizonte. **Anais...São José dos Campos: INPE, 2003. p. 2671 - 2677.**
- BREECE, H.T.; HOLMES, R.A. Bidirectional scattering characteristics of healthy green soybean and corn leaves “in vivo”. **Applied Optics**, v. 10, n.1, p. 119-127, 1971.
- CARVALHO, L.M.T.; CLEVERS, J.G.P.W.; SKIDMORE, A.K.; JONG, S.M. Selection of imagery data and classifiers for mapping Brazilian semideciduous Atlantic forests. **International Journal of Applied Earth Observation and Geoinformation**, v. 5, p. 173-186, 2004.
- CEPAM – CENTRO DE ESTUDOS E PESQUISAS DE ADMINISTRAÇÃO MUNICIPAL. Zanadrea, P. São Paulo: Cidade Universitária, 2005. On line. Disponível em: <http://www.cepam.sp.gov.br/v10/arquivos/redescobindo/Cap%E3o%20Bonito.pdf>. Acesso em 20 jul 2005.
- CLARK, M.L.; ROBERTS, D.A.; CLARK, D.B. Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scale. **Remote Sensing of Environment**, v. 96, n.3, p. 357-398, 2005.
- COCHRANE, M.A. Using vegetation reflectance variability for species level classification of hyperspectral data. **International Journal of Remote Sensing**, v. 21, n. 10, p. 2075-2087, 2000.

- COMBAL, B.; ISAKA, H. The effects of small topographic variations on reflectance. **IEEE Transaction on Geoscience and Remote Sensing**, v. 40, n. 3, p.663-670, 2002.
- COLWELL, J.E. Vegetation canopy reflectance. **Remote Sensing of Environment**, v. 3, p. 175-183, 1974.
- COOPS, N.C.; WHITE, J.D. Modeling forest productivity using data acquired through remote sensing. In: **Remote Sensing of Forest Environments: concepts and case studies**. USA: Kluwer Academic, 2003. 517 p.
- CORREIA, A. H. **Desenvolvimento do programa em IDL para correção de stripe da imagem Hyperion**. São José dos Campos: INPE, SP, 2006.
- DATT, B. Recognition of eucalyptus forest species using hyperspectral reflectance data. In: Geoscience and Remote Sensing Symposium, 2000. IGARSS'00, 20-24 Sep 2000. Honolulu. **Proceedings...Hawaii: IEEE**, v. 4, 2000, p. 1405-1407. ISBN 0780363590.
- DATT, B.; MCVICAR, T.R.; VAN NIEL, T.G.; JUPP, D.L.B.; PEARLMAN, J.S. Preprocessing EO-1 Hyperion hyperspectral data support the application of agricultural indexes. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 6, p. 1246-1259, 2003.
- FERNANDES, R.; MILLER, J.R.; HU, B.; RUBINSTEIN, J.G. A multiscale approach to mapping effective leaf area index in boreal Picea marina stands using high spatial resolution CASI imagery. **International Journal of Remote Sensing**, v. 23, p. 3547–3568, 2002.
- FERRAZ, P. **Influência da geometria de iluminação e do ângulo de visada na resposta espectral da cultura do feijão (Phaseolus vulgaris L.)**. 2006. 77 p. Dissertação (Mestrado em Agronomia). Escola Superior de Agricultura Luiz de Queiroz - ESALQ, Piracicaba, 2006.
- FOODY, G.M.; CUTLER, M.E. remote sensing of biodiversity: using neural networks to estimate the diversity and composition of a bornean tropical rainforest from landsat tm data. In: Geoscience and Remote Sensing Symposium, 2002. IGARSS '02. 24-28 Jul 2002. New Jersey. **Proceedings...USA: IEEE**, v. 1, 2002, p. 497-499. ISBN 0780387422.
- FOODY, G.M.; BOY, D.S.; CUTLER, M.E.J. Predictive relations of tropical forest biomass from Landsat TM data and their transferability between regions. **Remote Sensing of Environment**, v. 85, p. 463–474, 2003.
- FRANKLIN, S.E. **Remote sensing for sustainable forest management**. Boca Raton, Florida, USA: Lewis, 2001. 407 p. ISBN 1566703948.
- GALVÃO, L.S. Métodos para análise de espectro de reflectância. In: Meneses, P.R.; Menezes Neto, J.S. (orgs.). **Sensoriamento remoto: reflectância dos alvos naturais**. Brasília – DF: UnB, 2001. 262 p. ISBN 8523006567.
- GALVÃO, L.S.; FORMAGGIO, A.R.; TISOT, D.A. Discriminação de variedades de cana-de-açúcar com dados hiperespectrais do sensor Hyperion/EO-1. **Revista Brasileira de Cartografia**, v. 1, n. 57, p. 7-14, 2005.

- GAMON, J.A.; PENUELAS, J.; FIELD, C.B. A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. **Remote Sensing of Environment**, v. 41, p. 35-44, 1992.
- GARCIA-HARO, F.J.; SOMMER, S. A fast canopy reflectance model to simulate realistic remote sensing scenarios. **Remote Sensing of Environment**, v. 81, p. 205-227, 2002.
- GITELSON, A.A.; MERZLYAK, M.N. Spectral reflectance changes associated with autumn senescence of *Aesculus hippocastanum* L. and *Acer platanoides* L. leaves: spectral features and relation to chlorophyll estimation. **Journal of Plant Physiology**, v. 143, p. 286-292, 1994.
- GITELSON, A.A.; MERZLYAK, M.N.; CHIVKUNOVA, O.B. Optical properties and nondestructive estimation of anthocyanin content in plant leaves. **Photochemistry and Photobiology**, v. 71, p. 38-45, 2001.
- GOEL, N.S. Models of vegetation canopy reflectance and their use in estimation of biophysical parameters from reflectance data. **Remote Sensing Reviews**, v. 4, p. 1- 40, 1988.
- GOEL, N.S.; STREBEL, D.E. Simple beta distribution representation of leaf orientation in vegetation canopies. **Agronomy Journal**, v. 78, p. 800-803. 1984.
- GONG, P.; PU, R.; MILLER, J. R. Coniferous forest leaf area index estimation along the Oregon transect using compact airborne spectrographic imager data. **Photogrammetric Engineering and Remote Sensing**, v. 61, p. 1107– 1117, 1995.
- GONG, P.; PU, R.; YU, B., Conifer species recognition: an exploratory analysis of in situ hyperspectral data. **Remote Sensing of Environment**, v. 62, p. 189-200, 1997.
- GOODENOUGH, D.G.; DYK, A.; NIEMAN, 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.
- GOODWIN, N.; TURNER, R.; MERTON, R. Classifying Eucalyptus forests with high spatial and spectral resolution imagery: an investigation of individual species and vegetation communities. **Australian Journal of Botany**, v. 53, n. 4, p. 337-345, 2005.
- GREGOIRE, H.C.; RAFFY, M. Elaboration of multispectral models for heterogeneous media: application to the LAI. **Remote Sensing Reviews**, v. 15, p. 223-234, 1997.
- GROSS, H.; SCOTT, J. Applications of spectral analysis and image fusion techniques or images sharpening. **Remote Sensing of Environment**, v. 63, p. 85–94, 1998.
- HALL, R.J.; SKAKUN, R.S.; ARSENAULT, E.J.; CASE, B.S. Modeling forest stand structure attributes using Landsat ETM+ data: Application to mapping of aboveground biomass and stand volume. **Forest Ecology and Management**, v. 225, p. 378–390. 2006.
- HARDISKY, M.A.; KLEMAS, V.; SMART, R.M. The influences of soil salinity, growth form, and leaf moisture on the spectral reflectance of *Spartina alterniflora* canopies. **Photogrammetric Engineering and Remote Sensing**, v. 49, p. 77-83, 1983.

- HU, B., INANNEN, K., & MILLER, J. R. Retrieval of leaf area index and canopy closure from CASI data over the BOREAS flux tower sites. **Remote Sensing of Environment**, v. 74, p. 255– 274, 2000.
- HUETE, A.R. **Soil spectral effects on vegetation discrimination**. 1988. 208 p. Tese (Doutorado em Solos, Água e Engenharia), Universidade do Arizona, USA. 1988.
- HUNT JR., E.R.; ROCK, B.N. Detection of Changes in Leaf Water Content Using Near-And Middle-Infrared Reflectances. **Remote Sensing of Environment**, v. 30, p. 43-54, 1989.
- IBAMA – INSTITUTO BRASILEIRO DE MEIO AMBIENTE E DOS RECURSOS NATURAIS RENOVÁVEIS. **Unidades de conservação, florestas nacionais, Região Sudeste**. On line. Disponível em: [http://www.ibama.gov.br/sp/index.php?id\\_menu=190](http://www.ibama.gov.br/sp/index.php?id_menu=190). Acesso em 30 nov 2006.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Mapa de Vegetação do Brasil**. 2004, 3ª Ed. Escala 1: 5.000.000.
- JENSEN, J.R. **Remote sensing of the environment: an earth resource perspective**. USA: Prentice-Hall, 2000. 544 p. ISBN 0134897331.
- JOLLIFFE, I.T. **Principal component analysis**. 2. Ed. UK: Springer, 2002. 487 p. ISBN 0387954422.
- KAUTH, R.J.; THOMAS, G.S. The tasseled cap- a graphic description of the spectral-temporal development of agricultural crops as seen by Landsat. In: Symposium on Machine Processing of Remotely Sensed Data, Purdue University, West Lafayette, jun 1976, Indiana. **Proceedings...** West Lafayette, Indiana, 1976, p. 4B-41-4B-50.
- KAYITAKIRE, F.; HAMEL, C.; DEFOURNY, P. Retrieving forest structure variables based on image texture analysis and IKONOS-2 imagery. **Remote Sensing of Environment**, v. 102, p. 390–401, 2006.
- KIMES, D.S. Dynamics of directional reflectance factor distributions for vegetation canopies. **Applied Optics**, v. 22, n. 9, p. 1364-1372, 1983.
- KIMES, D.S.; KIRCHNER, J.A. Diurnal variations of vegetation canopy structure. **International Journal of Remote Sensing**, v. 4, n. 2, p. 257-271, 1983.
- KRUSE, F.A.; BOARDMAN, J.W.; HUNTINGTON, J.F. Comparison of airborne hyperspectral data and EO-1 Hyperion for mineral mapping. **IEEE Transactions on Geoscience and Remote Sensing**, v 41, n. 6, p. 1388-1400, 2003.
- LATORRE, M.L.; DIAS, A.V.; SHIMABUKURO, Y.E.; JÚNIOR, O.A.C A influência dos efeitos da geometria de iluminação na análise de alvos de superfície terrestre obtidos a partir de dados AVIRIS. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 10, 21 a 26 abr. 2001, Foz do Iguaçu. **Anais...**São José dos Campos: INPE, 2001. Artigos. p. 1293-1300. ISBN 85-17-00016-1. On line. Disponível em: <http://marte.dpi.inpe.br/col/dpi.inpe.br/lise/2001/09.20.17.44/doc/1293.1300.053.pdf> Acesso em 15 nov. 2007.

- LI, X. STRAHLER, A.H. Geometric-optical bi-directional reflectance modeling of mutual shadowing effects of crowns in a forest. **IEEE Transaction on Geoscience and Remote Sensing**, n. 30, p. 276-292, 1992.
- LIESENBERG, V.; GALVÃO, L.S.; PONZONI, F.J. Variations in reflectance with seasonality and viewing geometry: implications for classification of Brazilian savannah physiognomies with MISR/Terra data. **Remote Sensing of Environment**, n. 107, p.276-286, 2007.
- LILLESAND, T.M.; R.W. KIEFER; J.W. CHIPMAN.. **Remote sensing and image interpretation**. 5ª Ed. New York: Wiley, 2004. 763 p. ISBN 0471451525.
- LU, d.; MAUSEL, P.; BRONDÍZIO, E.; MORAN, E. Relationships between forest stand parameters and Landsat TM spectral responses in the Brazilian Amazon Basin. **Forest Ecology and Management**, v.198, p. 149–167, 2004.
- LUCAS, N. S.; CURRAN, P. J.; PLUMMER, S. E.; DANSON, F. M. Estimating the stem carbon production of a coniferous forest using an ecosystem simulation model driven by the remotely sensed red edge. **International Journal of Remote Sensing**, v. 21, p. 619– 631, 2000.
- MÄKELÄ, H.; PEKKARIEN, A. Estimation of forest stand volumes by Landsat TM imagery and stand-level field-inventory data. **Forest Ecology and Management**, v. 196 p. 245–255, 2004.
- MATTHEW, M.W.; ADLER-GOLDEN, S.M.; BER, A. Atmospheric correction of spectral imagery: evaluation of the FLAASH algorithm with AVIRIS data. In: Applied Imagery Pattern Recognition Workshop, 31, AIPR.02. 16-17 Oct. 2002. **Proceedings...** 2002, p. 157- 163. ISBN 076951863X.
- NIEMANN, K.O. Remote sensing of forest stand age using airborne spectrometer data. **Photogrammetric Engineering and Remote Sensing**, v. 61, n. 9, p. 1119-1127, 1995.
- OLIVEIRA, J.B.O; CAMARGO, M.N.; ROSSI, M.; CALDERANO FILHO, B. **Mapa pedológico do Estado de São Paulo: legenda expandida**. Campinas: Instituto Agrônomo/ EMBRAPA Solos, 1999. 64 p.
- PENUELAS, J.; FILELLA, I.; BIEL,C; SERRANO, L.; SAVE, R. The reflectance at the 950-970 region as an indicator of plant water status. **International Journal of Remote Sensing**, v. 14, p. 1887-1905, 1996.
- POCEWICZ, A., VIERLING, L.A., LENTILE, L.B., SMITH, R. View angle effects on relationships between MISR vegetation indices and leaf area index in a recently burned ponderosa pine forest. **Remote Sensing of Environment**, n. 107, p. 322-333, 2007.
- PONZONI, F.J. Comportamento espectral da vegetação. In: Meneses, P.R. e Netto, J.S.M. (Org.) **Sensoriamento remoto: reflectância dos alvos naturais**. Brasília, DF:UNB, 2001. 262 p. ISBN 8523006567.
- PONZONI, F.J.; SHIMABUKURO, Y.E. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos, SP: Silva Vieira, 2007. 135 p. ISBN 9788560507023.

- RICHARDS, J.A.; JIA, X. **Remote sensing digital image analysis: an introduction**. 4<sup>a</sup> Ed. Germany: Springer, 2006. 439 p. ISBN 3540251286.
- ROSS, J.L.S.; MOROZ, I.C. **Mapa geomorfológico do Estado de São Paulo**. v. 1, Escala 1:500.000. 1997.
- ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W. Monitoring vegetation systems in the great plains with ERTS. In: ERTS Symposium, 3, 1973, Washington, DC. **Proceedings...** Washington, EUA: NASA, 1973. p. 309-317.
- RUMMEL, R.J. **Applied factor analysis**. Evanston, USA: Northwestern University Press, 1970. 609 p.
- SCHMIDT, K.S.; SKIDMORE, A.K. Spectral discrimination of vegetation types in a coastal wetland. **Remote Sensing of Environment**, v. 85, p. 92-108, 2003.
- SBS – Sociedade Brasileira de Silvicultura. **Estatísticas**. Disponível em: [www.sbs.org.br](http://www.sbs.org.br). Acesso em 09 ago 2005.
- SCHLERF, M.; ATZBERGER, C.; HILL, J. Remote sensing of forest biophysical variables using HyMap imaging spectrometer data. **Remote Sensing of Environment**, v. 95, p. 177-194, 2005.
- SCHOWENGERDT, R.A. **Remote sensing: models and methods for image processing**. 3<sup>a</sup> Ed. USA: Elsevier, 2007. 515 p. ISBN 9780123694072.
- SCOLFORO, J.R.S. **Modelagem de crescimento e da produção de florestas plantadas e nativas**. Lavras: UFLA/FAEPE, 1998. 441 p.
- SETZER, J. **Contribuição para o estudo do clima do Estado de São Paulo**. São Paulo: Escolas Profissionais Salesianas, 1946. 239 p.
- STEININGER, M.K. Satellite estimation of tropical secondary forest above ground biomass: data from Brazil and Bolivia. **International Journal of Remote Sensing**, n. 21, p. 1139-1157, 2000.
- THENKABAIL, P.S.; ENCLONA, E.A.; ASHTON, M.S.; LEGG, C.; DE DIEU, M.J. Hyperion, IKONOS, ALI, and ETM+ sensors in the study of African rainforests. **Remote Sensing of Environment**, v. 90, n. 1, p. 23-43, 2004.
- THENKABAIL, P.S.; HALL, J.; LIN, T.; ASHTON, M.S.; HARRIS, D.; ENCLONA, E.A. Detecting floristic structure and pattern across topographic and moisture gradients in a mixed species Central African forest using IKONOS and Landsat-7 ETM+ images. **International Journal of Applied Earth Observation and Geoinformation**, v. 4, p. 255-270, 2003.
- UNDERWOOD, E.; USTIN, S.; DIPIETRO, D. Mapping nonnative plants using hyperspectral imagery. **Remote Sensing of Environment**, v. 86, p. 150-161, 2003.
- USGS - UNITES STATES GEOLOGICAL SURVEY. EO-1 (Earth Observing-1). **Sensors/ dados SRTM**. Disponível em <http://eo1.usgs.gov/>. Acesso em 01 ago 2005.

VALERIANO, M.M. **Equação para o cálculo do fator de iluminação**. São José dos Campos, SP, 2006.

VALERIANO, M.M. Modelo digital de variáveis morfológicas com dados SRTM para o território nacional: o projeto TOPODATA. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 12, 16 a 21 abr. 2005, Goiânia. **Anais...**São José dos Campos: INPE, 2005. Artigos. p. 3595-3602. ISBN 85-17-00018-8. On-line. Disponível em: <http://martemarte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/10.29.11.41/doc/3595.pdf>. Acesso em 04 jun. 2006.

VALERIANO, M.M. **Modelo digital de elevação com dados SRTM disponíveis para a América do Sul**. São José dos Campos, SP: INPE, 2004. 72 p. (INPE-10550-RPQ/756).

VOGELMANN, J.E.; ROCK, B.N.; MOSS, D.M. Red edge spectral measurements from sugar maple leaves. **International Journal of Remote Sensing**, v. 14, p. 1563-1575, 1993.

WANGLIN, Y. 1998. **Image processing technique**: spectrum analysis of 7th satellite image. Disponível em <http://ecogis.sfc.keio.ac.jp/online/ipt/2002/Lecture7/Cap.gif>. Acesso em: 10 jan 2008.

## APÊNDICE A

Apêndice A.1 – Programa em IDL para correção do *striping* (Correia, 2006).

```
=====
;
PRO correcao_bad_sample_hyperion, ev
WIDGET_CONTROL, ev.id, get_uvalue = uvalue
IF (uvalue EQ 'correcao_bad_sample_hyperion') THEN BEGIN
    envi_select, title='Selecione a imagem HYPERION', fid=fid, pos=pos, dims=dims
    if fid eq -1 then return
    ;
    ;=====
    ; get ENVI file header information
    ;=====
    ENVI_FILE_QUERY, fid,/NO_REALIZE, ns=ns, nl nl, BYTE_SWAP = byteswap,
data_type=data_type, fname=fname
    ncol = long(ns)
    nlin = long(nl)
    n_band = n_elements(pos)
    img_out = make_array(ncol,nlin,n_band,type=data_type)
    temp=['Input HYPERION image: ' + fname]
    ENVI_REPORT_INIT, temp, TITLE='Leitura da imagem HYPERION...',base=base,
/Interrupt
    ENVI_REPORT_INC, base, n_band
    for i=0,n_band-1 do begin
        img_out(*,*,i) = ENVI_GET_DATA(fid=fid, dims=dims, pos=i)
        ENVI_REPORT_STAT, base, i+1, n_band, Cancel=Cancel
        if cancel eq 1 then begin
            Envi_Report_Init,Base=Base,/Finish
            return
        endif
    ENDFOR
    ENVI_REPORT_INIT,base=base, /Finish
    ;=====
    ; leitura das imagens
    ;=====
    ;img = ENVI_GET_DATA(fid=fid, dims=dims, pos=pos)
    bad_band = [ 9, 10, 11, 12, 13, 14, 15, 16, 17, 18,$
                19, 20, 21, 22, 23, 24, 25, 26, 27, 28,$
                29, 30, 31, 32, 33, 34, 55, 77,120,121,$
                122,123,124,125,126,127,128,129,130,132,$
                165,168,174,178,181,186,191,221,222,223]

    bad_col = ptrarr(n_elements(bad_band))

    bad_col[0] = ptr_new([6,68,114,121]) ;banda 9
    bad_col[1:2] = ptr_new([6,114,199]) ;banda 10-11
    bad_col[3] = ptr_new([6,114]) ;banda 12
    bad_col[4] = ptr_new([114]) ;banda 13
```

```

bad_col[5] = ptr_new([114,247])      ;banda 14
bad_col[6:25] = ptr_new([114])      ;banda 15-34
bad_col[26] = ptr_new([13,20])      ;banda 55
bad_col[27] = ptr_new([250])        ;banda 77
bad_col[28] = ptr_new([194])        ;banda 120
bad_col[29] = ptr_new([231])        ;banda 121
bad_col[30] = ptr_new([150,204])    ;banda 122
bad_col[31] = ptr_new([79,87,125,169,179,194]) ;banda 123
bad_col[32] = ptr_new([66,131,133,152,158,201]) ;banda 124
bad_col[33] = ptr_new([180,221,253]) ;banda 125
bad_col[34] = ptr_new([29,67,110,121,127,133,187,191,249]) ;banda 126
bad_col[35] = ptr_new([215])        ;banda 127
bad_col[36] = ptr_new([45,146,223,240]) ;banda 128
bad_col[37] = ptr_new([5,73,223])   ;banda 129
bad_col[38] = ptr_new([67,72,83,120,169,194,209,223,233]) ;banda 130
bad_col[39] = ptr_new([90,245])     ;banda 132
bad_col[40] = ptr_new([147])        ;banda 165
bad_col[41] = ptr_new([2,229])      ;banda 168
bad_col[42] = ptr_new([226])        ;banda 174
bad_col[43] = ptr_new([202,246])    ;banda 178
bad_col[44] = ptr_new([190])        ;banda 181
bad_col[45] = ptr_new([110,198])    ;banda 186
bad_col[46] = ptr_new([193])        ;banda 191
bad_col[47] = ptr_new([246])        ;banda 221
bad_col[48] = ptr_new([97])         ;banda 222
bad_col[49] = ptr_new([95])         ;banda 223

```

```

temp=['Input HYPERION image: ' + fname, $
      'Output fixed HYPERION band:' + strjoin(strtrim(bad_band,2),',')]

```

```

ENVI_REPORT_INIT, temp, TITLE='Correção das colunas da imagem
HYPERION...',base=base, /Interrupt
ENVI_REPORT_INC, base, n_elements(bad_band)
for i = 0,n_elements(bad_band)-1 do begin
    banda = img_out(*,*,bad_band[i]-1)

    ; o valor -1 é subtraído das colunas porque o IDL começa a
    ; contar as linhas e colunas no valor 0
    col_bad = *bad_col[i]-11

    For j = 0,n_elements(col_bad)-1 do begin
        banda(col_bad[j],*)=( banda(col_bad[j]-1,*)+banda(col_bad[j]+1,*) )/2
        img_out(*,*,bad_band[i]-1) = banda
    endfor
    ; salva a banda da imagem hyperion corrigida
    ; fname_out = fname + '_band_' + strtrim(bad_band[i],2) + '_fix.img'
    ;ENVI_WRITE_ENVI_FILE, img, out_name=fname_out, nb=1, ns=ncol, nl=nlin
    ENVI_REPORT_STAT, base,i+1, n_elements(bad_band), Cancel=Cancel
if cancel eq 1 then begin
    Envi_Report_Init,Base=Base,/Finish

```

```
        return
    endif

ENDFOR
ENVI_REPORT_INIT,base=base,/Finish
; salva a imagem hyperion corrigida
fname_out = fname + '_fix.img'
ENVI_WRITE_ENVI_FILE, img_out, out_name=fname_out, nb=n_elements(pos), ns=ncol,
nl=nlin
endif
END
```

Apêndice A.2 – Autovetores gerados pela análise de componente principal para a imagem Hyperion.

Comprimento de Onda (nm)	Componente		Comprimento de Onda (nm)	Componente		Comprimento de Onda (nm)	Componente	
	PC1	PC2		PC1	PC2		PC1	PC2
508	0,688	0,147	620	0,85	0,166	732	-0,531	0,723
518	0,678	0,181	630	0,81	0,125	742	-0,646	0,736
529	0,758	0,293	641	0,553	0,143	752	-0,659	0,724
539	0,671	0,352	651	0,896	0,1	763	-0,684	0,701
549	0,708	0,381	661	0,921	9,70E-02	773	-0,687	0,702
559	0,603	0,334	671	0,912	6,86E-02	783	-0,681	0,709
569	0,814	0,344	681	0,867	6,14E-02	793	-0,679	0,711
579	0,83	0,253	691	0,909	7,18E-02	803	-0,677	0,714
590	0,801	0,193	702	0,855	0,221	813	-0,667	0,712
600	0,803	0,219	712	0,147	0,808	824	-0,68	0,713
610	0,883	0,199	722	-0,359	0,833	834	-0,676	0,714
844	-0,672	0,724	1266	-0,194	0,951	1810	0,618	0,292
854	-0,671	0,726	1276	-0,191	0,949	1942	0,118	-0,253
864	-0,669	0,727	1286	-0,157	0,96	1952	0,303	-0,242
875	-0,668	0,729	1296	-0,112	0,962	2022	0,905	1,72E-02
885	-0,664	0,731	1306	-0,034	0,957	2032	0,934	4,29E-02
895	-0,655	0,734	1316	0,074	0,963	2042	0,928	7,45E-02
905	-0,664	0,723	1326	0,204	0,922	2052	0,894	7,28E-02
915	-0,631	0,709	1336	0,277	0,777	2063	0,94	8,23E-02
923	-0,351	0,435	1346	0,16	0,398	2073	0,944	9,08E-02
933	-0,516	0,612	1477	0,899	0,113	2083	0,938	0,107
943	-0,443	0,537	1488	0,924	0,166	2093	0,933	0,118
953	-0,542	0,719	1498	0,946	0,231	2103	0,932	0,133
963	-0,557	0,755	1508	0,943	0,262	2113	0,931	0,146
973	-0,576	0,78	1518	0,937	0,292	2123	0,914	0,177
983	-0,574	0,791	1528	0,929	0,323	2133	0,919	0,197
993	-0,565	0,806	1538	0,919	0,353	2143	0,963	0,177
1003	-0,571	0,802	1548	0,91	0,374	2153	0,96	0,192
1013	-0,518	0,708	1558	0,9	0,392	2163	0,939	0,199
1023	-0,59	0,788	1568	0,89	0,41	2174	0,927	0,215
1034	-0,601	0,778	1578	0,883	0,43	2184	0,921	0,228
1044	-0,599	0,768	1588	0,872	0,449	2194	0,904	0,233
1054	-0,586	0,79	1599	0,863	0,467	2204	0,884	0,231
1064	-0,576	0,782	1609	0,854	0,48	2214	0,923	0,24
1074	-0,592	0,788	1619	0,843	0,501	2224	0,951	0,233
1084	-0,585	0,796	1629	0,835	0,513	2234	0,953	0,224
1094	-0,575	0,8	1639	0,826	0,531	2244	0,929	0,258
1104	-0,557	0,805	1649	0,818	0,543	2254	0,913	0,248
1114	-0,517	0,795	1659	0,809	0,554	2264	0,929	0,219
1124	-0,478	0,772	1669	0,804	0,562	2274	0,932	0,197
1134	-0,401	0,796	1679	0,804	0,56	2285	0,911	0,21
1144	-0,315	0,827	1689	0,8	0,565	2295	0,903	0,199
1155	-0,25	0,92	1699	0,793	0,572	2305	0,928	0,157

Apêndice A.2 – Autovetores gerados pela análise de componente principal para a imagem Hyperion (Continuação).

Comprimento de Onda (nm)	Componente		Comprimento de Onda (nm)	Componente		Comprimento de Onda (nm)	Componente	
	PC1	PC2		PC1	PC2		PC1	PC2
1165	-0,241	0,943	1710	0,792	0,572	2315	0,938	0.135
1175	-0,224	0,941	1720	0,803	0,562	2325	0,94	0.142
1185	-0,197	0,94	1730	0,812	0,55	2335	0,934	0.133
1195	-0,203	0,949	1740	0,827	0,532	2345	0,944	8.69E-02
1205	-0,196	0,952	1750	0,843	0,513	2355	0,947	7.68E-02
1215	-0,213	0,946	1760	0,856	0,488	2365	0,943	7.38E-02
1225	-0,225	0,947	1770	0,869	0,461	2375	0,926	4.68E-02
1235	-0,189	0,955	1780	0,871	0,44	2385	0,954	2.95E-02
1245	-0,19	0,962	1790	0,878	0,431	2396	0,95	2.96E-02
1255	-0,193	0,919	1800	0,798	0,386			

## **PUBLICAÇÕES TÉCNICO-CIENTÍFICAS EDITADAS PELO INPE**

### **Teses e Dissertações (TDI)**

Teses e Dissertações apresentadas nos Cursos de Pós-Graduação do INPE.

### **Manuais Técnicos (MAN)**

São publicações de caráter técnico que incluem normas, procedimentos, instruções e orientações.

### **Notas Técnico-Científicas (NTC)**

Incluem resultados preliminares de pesquisa, descrição de equipamentos, descrição e ou documentação de programa de computador, descrição de sistemas e experimentos, apresentação de testes, dados, atlas, e documentação de projetos de engenharia.

### **Relatórios de Pesquisa (RPQ)**

Reportam resultados ou progressos de pesquisas tanto de natureza técnica quanto científica, cujo nível seja compatível com o de uma publicação em periódico nacional ou internacional.

### **Propostas e Relatórios de Projetos (PRP)**

São propostas de projetos técnico-científicos e relatórios de acompanhamento de projetos, atividades e convênios.

### **Publicações Didáticas (PUD)**

Incluem apostilas, notas de aula e manuais didáticos.

### **Publicações Seriadas**

São os seriados técnico-científicos: boletins, periódicos, anuários e anais de eventos (simpósios e congressos). Constam destas publicações o Internacional Standard Serial Number (ISSN), que é um código único e definitivo para identificação de títulos de seriados.

### **Programas de Computador (PDC)**

São a seqüência de instruções ou códigos, expressos em uma linguagem de programação compilada ou interpretada, a ser executada por um computador para alcançar um determinado objetivo. São aceitos tanto programas fonte quanto executáveis.

### **Pré-publicações (PRE)**

Todos os artigos publicados em periódicos, anais e como capítulos de livros.