



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21b/2017/05.13.00.14-TDI

**DETECÇÃO DE ESPÉCIES ARBÓREAS EM FLORESTA  
ESTACIONAL SEMIDECIDUAL POR  
SENSORIAMENTO REMOTO HIPERESPECTRAL E  
MODELAGEM DE TRANSFERÊNCIA RADIATIVA**

Matheus Pinheiro Ferreira

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Yosio Edemir Shimabukuro, e Carlos Roberto de Souza Filho, aprovada em 19 de maio de 2017.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3NSEFF5>>

INPE  
São José dos Campos  
2017

**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) 3208-6923/6921

E-mail: pubtc@inpe.br

**COMISSÃO DO CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO  
DA PRODUÇÃO INTELECTUAL DO INPE (DE/DIR-544):****Presidente:**

Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação (CPG)

**Membros:**

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (CST)

Dr. André de Castro Milone - Coordenação de Ciências Espaciais e Atmosféricas  
(CEA)

Dra. Carina de Barros Melo - Coordenação de Laboratórios Associados (CTE)

Dr. Evandro Marconi Rocco - Coordenação de Engenharia e Tecnologia Espacial  
(ETE)

Dr. Hermann Johann Heinrich Kux - Coordenação de Observação da Terra (OBT)

Dr. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos  
Climáticos (CPT)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SID)

**BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SID)

**REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

Simone Angélica Del Duca Barbedo - Serviço de Informação e Documentação  
(SID)

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

**EDITORAÇÃO ELETRÔNICA:**

Marcelo de Castro Pazos - Serviço de Informação e Documentação (SID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SID)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21b/2017/05.13.00.14-TDI

**DETECÇÃO DE ESPÉCIES ARBÓREAS EM FLORESTA  
ESTACIONAL SEMIDECIDUAL POR  
SENSORIAMENTO REMOTO HIPERESPECTRAL E  
MODELAGEM DE TRANSFERÊNCIA RADIATIVA**

Matheus Pinheiro Ferreira

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Yosio Edemir Shimabukuro, e Carlos Roberto de Souza Filho, aprovada em 19 de maio de 2017.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3NSEFF5>>

INPE  
São José dos Campos  
2017

Dados Internacionais de Catalogação na Publicação (CIP)

---

Ferreira, Matheus Pinheiro.

F413d Detecção de espécies arbóreas em floresta estacional semidecidual por sensoriamento remoto hiperespectral e modelagem de transferência radiativa / Matheus Pinheiro Ferreira. – São José dos Campos : INPE, 2017.

xxx + 118 p. ; (sid.inpe.br/mtc-m21b/2017/05.13.00.14-TDI)

Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2017.

Orientadores : Drs. Yosio Edemir Shimabukuro, e Carlos Roberto de Souza Filho.

1. Sensoriamento remoto hiperespectral. 2. Floresta Atlântica. 3. WorldView-3. 4. DART. I.Título.

CDU 528.831.2(253)

---



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

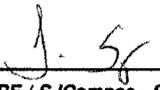
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **Matheus Pinheiro Ferreira**

"DETECÇÃO DE ESPÉCIES ARBÓREAS EM FLORESTA ESTACIONAL SEMIDECIDUAL POR SENSORIAMENTO REMOTO HIPERESPECTRAL E MODELAGEM DE TRANSFERÊNCIA RADIATIVA".

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

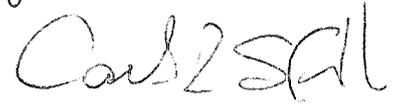
Dr. Lênio Soares Galvão

  
\_\_\_\_\_  
Presidente / INPE / SJCampos - SP

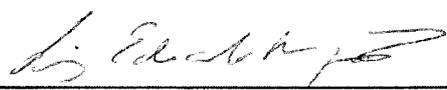
Dr. Yosio Edemir Shimabukuro

  
\_\_\_\_\_  
Orientador(a) / INPE / São José dos Campos - SP

Dr. Carlos Roberto de Souza Filho

  
\_\_\_\_\_  
Orientador(a) / UNICAMP / Campinas - SP

Dr. Luiz Eduardo Oliveira e Cruz de Aragão

  
\_\_\_\_\_  
Membro da Banca / INPE / São José dos Campos - SP

Dr. Teodoro Isnard Ribeiro de Almeida

  
\_\_\_\_\_  
Convidado(a) / USP / São Paulo - SP

Dr. Thiago Sanna Freire Silva

  
\_\_\_\_\_  
Convidado(a) / UNESP / Rio Claro - SP

Este trabalho foi aprovado por:

( ) maioria simples

(x) unanimidade

São José dos Campos, 19 de maio de 2017



*“Science never solves a problem without creating ten more”.*

*George Bernard Shaw*



*Dedico esta Tese de Doutorado a meus pais Francisco e Eni, a minha irmã Manuela e a minha noiva Mariana.*



## AGRADECIMENTOS

Aos meus orientadores Dr. Yosio Edemir Shimabukuro e Dr. Carlos Roberto de Souza Filho sem os quais a realização desta pesquisa não seria possível. Agradeço pela motivação e confiança em mim depositada ao longo desses anos.

Aos Drs. Jean-Baptiste Féret e Eloi Grau da *Maison de la Télédétection*, centro de excelência em sensoriamento remoto e modelagem de transferência radiativa, pelo grande apoio no desenvolvimento desta pesquisa, pela amizade e companheirismo.

Aos Drs. Maciel Zortea e Daniel Zanotta com quem muito aprendi sobre processamento e análise de dados hiperespectrais.

A todos os colegas do curso de pós-graduação em sensoriamento remoto do INPE com quem compartilhei ideias e frustrações.

Ao Dr. Fabiano Farah, Mario Raczynski e Valdivino Lima Santos pela paciência e parceria durante as várias etapas do trabalho de campo.

Aos funcionários da ARIE Mata de Santa Genebra, em especial ao Cristiano, Laís e Celina pelo apoio em todas as atividades desta pesquisa.

Ao Laboratório de Espectroscopia de Reflectância (LER) do Departamento de Geociências (IG) da Universidade Estadual de Campinas (UNICAMP) pela infraestrutura e equipamentos necessários para coleta de propriedades ópticas foliares.

Ao Instituto Nacional de Pesquisas Espaciais (INPE), pela excelência do curso de pós-graduação em sensoriamento remoto e pela infraestrutura fornecida para realização do trabalho. Especiais agradecimentos à Valéria e Vera da secretaria e aos coordenadores Dr. Flávio Ponzoni, Dr. Camilo Renó e Dra. Elisabete Moraes.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão de bolsa de doutorado sanduíche no âmbito do Programa de Doutorado Sanduíche no Exterior (PDSE) (processo nº 3424/2015-04) para realização de estágio no centro de sensoriamento remoto (*Maison de la Télédétection*) na cidade de Montpellier/França.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão da bolsa de doutorado (processo nº 140398/2013-9) no período de 01/03/2013 a 31/08/2013.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), pela concessão da bolsa de doutorado (processo nº 2013/11589-5) no período de 01/09/2013 a 31/05/2017.

A minha querida noiva, Mariana, pelo amor, incentivo e por ter sempre apoiado minhas decisões.

A meus pais Francisco e Eni e a minha irmã Manuela pelo apoio incondicional em todos os momentos.

## RESUMO

O mapeamento da distribuição espacial de espécies arbóreas em ambientes tropicais fornece informações valiosas para ecólogos e gestores florestais. Esse procedimento pode reduzir custos com trabalhos de campo, auxiliar o monitoramento da diversidade florística do dossel e auxiliar a localização de árvores matrizes para a coleta de sementes em iniciativas de restauração florestal. Entretanto, a detecção de espécies arbóreas em florestas tropicais com dados de sensoriamento remoto é um desafio devido à elevada diversidade espectral e florística. O objetivo principal desta pesquisa de doutorado foi explorar a utilização de dados reais e simulados de sensoriamento remoto multi e hiperespectral para mapear e classificar espécies arbóreas da Floresta Estacional Semidecidual. Os objetivos específicos incluíram: (i) avaliar o desempenho de métodos estatísticos de classificação na discriminação de espécies arbóreas da área de estudo; (ii) identificar regiões e bandas espectrais, no intervalo de 450 a 2400 nm, propícias à classificação das espécies; (iii) avaliar a utilização de índices de vegetação de bandas estreitas na discriminação das espécies; (iv) quantificar a variabilidade espectral intra e interespecífica, bem como sua influência, na classificação das espécies; (v) desenvolver um método para o mapeamento automático das espécies ao nível de árvores individuais; (vi) desenvolver uma abordagem de simulação da resposta espectral das espécies ao nível de dossel a partir da utilização de modelagem de transferência radiativa em três dimensões (3D) e (vii) comparar a resposta espectral simulada e medida das espécies. Três métodos de classificação supervisionada foram testados para discriminar oito espécies arbóreas: Análise Discriminante Linear (LDA), Support Vector Machines com kernel linear (L-SVM) e função de base radial (RBF-SVM) e Random Forest (RF). Uma exatidão de classificação média de 70% foi obtida ao se utilizar as bandas do visível/infravermelho próximo (VNIR, 450-919 nm). A inclusão de bandas do infravermelho de ondas curtas (SWIR, 1045-2400 nm) elevaram a exatidão para 84%. Índices de vegetação de bandas estreitas também foram testados e elevaram a exatidão em 5% quando combinados a bandas do VNIR. Dados reais e simulados do sensor WorldView-3 (WV-3) foram utilizados para fins de classificação. Enquanto as bandas VNIR simuladas de sensor forneceram uma exatidão de 57,4%, o conjunto VNIR+SWIR aumentou a exatidão para 74,8%. Este padrão se manteve na classificação de dados WV-3 reais (aumento de 3,2 % após a inclusão de bandas SWIR). O grau de sobreposição das variabilidades intra e interespecífica influenciou diretamente as classificações. O método para mapeamento de árvores desenvolvido produziu mapas fidedignos da distribuição espacial das espécies e elevou a exatidão em relação às classificações ao nível de pixel em até 6%. Um procedimento de seleção de atributos baseado em regressão stepwise identificou bandas localizadas ao redor do pico do verde (550 nm), na feição de absorção do vermelho (650 nm) e no SWIR em 1200, 1700, 2100 e 2300 nm, como úteis para discriminar as espécies. A resposta espectral das espécies no VNIR foi acuradamente simulada pelo modelo Discrete Anisotropic Radiative Transfer (DART) que opera em três dimensões (3D). Por meio de uma estrutura simplificada da copa, a resposta espectral das espécies no topo do dossel foi

simulada com até 1,5% de erro quadrático médio. A inversão do modelo na imagem hiperespectral gerou relações estatísticas significantes ( $R^2=0,65$ ) entre o conteúdo de clorofila ( $C_{ab}$ ) e o índice MCARI (Modified Chlorophyll Absorption in Reflectance Index), sendo  $C_{ab}$  estatisticamente diferente entre as espécies. A abordagem de simulação desenvolvida pode ser utilizada para reproduzir aquisições hiperespectrais de florestas tropicais.

Palavras-chave: Sensoriamento remoto hiperespectral. Floresta Atlântica. WorldView-3. DART.

# **TREE SPECIES DISCRIMINATION IN TROPICAL SEMI-DECIDUOUS FOREST WITH REMOTELY SENSED DATA AND RADIATIVE TRANSFER MODELING**

## **ABSTRACT**

Accurately mapping the spatial distribution of tree species in tropical environments provides valuable insights for ecologists and forest managers. This process may play an important role in reducing fieldwork costs, monitoring changes in canopy biodiversity, and locating parent trees to collect seeds for forest restoration efforts. However, mapping tree species in tropical forests with remote sensing data is a challenge because of high floristic and spectral diversity. The main objective of this study was to explore the use of experimental and simulated multi and hyperspectral remotely sensed data for tree species discrimination and mapping in a tropical seasonal semi-deciduous forest. Specifically we aimed: (i) to evaluate the performance of machine learning methods in the discrimination of tree species of the study area; (ii) to identify spectral regions and bands, in 450-2400 nm range, suitable for species classification; (iii) to evaluate the use of narrow band vegetation indices in species discrimination; (iv) to quantify within- and among-species spectral variability as well as its influence on species classification; (v) develop a method for tree species mapping at the individual tree level; (vi) to develop a modeling approach to simulate the spectral response of the species at the canopy level using three-dimensional (3D) radiative transfer modeling and (vii) to compare simulated and measured spectral responses of the species. Three classifiers were tested to discriminate eight tree species: Linear Discriminant Analysis (LDA), Support Vector Machines with linear kernel (L-SVM) and radial base function (RBF-SVM) and Random Forest (RF). An average classification accuracy of 70% was obtained when using the visible/near-infrared bands (VNIR, 450-919 nm). The inclusion of short-wave infrared (SWIR, 1045-2400 nm) bands changed the accuracy to 84%. Narrow-band vegetation indices were also tested and increased the classification accuracy by up to 5% when combined with VNIR features. Experimental and simulated data of the WorldView-3 (WV-3) sensor were used for classification purposes. While the simulated VNIR sensor bands provided an accuracy of 57.4%, the VNIR + SWIR set increased accuracy to 74.8%. This pattern was also observed in the classification of experimental WV-3 data (increase of 3.2% after inclusion of SWIR bands). The degree of overlap between the within- and among-species spectral variability influenced the classifications. The developed tree mapping method produced reliable maps of the spatial distribution of the species and increased accuracy in relation to pixel-level classifications by up to 6%. The use of a reduced set of hyperspectral bands did not significantly affect the classification accuracies but allowed us to depict the most important wavelengths to discriminate the species. These wavelengths were located around the green reflectance peak (550 nm), at the red absorption feature (650 nm) and in the SWIR range at 1200, 1700, 2100 and 2300 nm. The spectral response of the species in the VNIR was accurately simulated by the Discrete Anisotropic Radiative Transfer (DART) model that operates in 3D. By means of a simplified

crown structure, the spectral response of the species at the top of the canopy was simulated with an error of 1.5%. The inversion of the model in the hyperspectral image provided statistical significant relationships ( $R^2=0.65$ ) between chlorophyll content ( $C_{ab}$ ) and MCARI (Modified Chlorophyll Absorption in Reflectance Index), being  $C_{ab}$  statistically different among the species. The developed modeling approach can be used to simulate hyperspectral acquisitions of tropical forests.

Keywords: Hyperspectral remote sensing. Atlantic Forest. WorldView-3. DART.

## LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 – Mapa de espécies arbóreas.....	10
Figura 2.2 – Representação esquemática do fluxo de radiação.....	13
Figura 2.3 – Representação de uma floresta boreal simulada. ....	16
Figura 2.4 – Coeficientes utilizados no modelo de transferência radiativa dentro de folhas (PROSPECT-5). ....	19
Figura 2.5 – Modelo conceitual utilizado para simulação de processos de transferência radiativa pelo modelo Discrete Anisotropic Radiative Transfer (DART). 21	21
Figura 2.6 – Simulação de uma floresta tropical pelo modelo DART. A distribuição das árvores é aleatória, bem como seu formato e tamanho. ....	23
Figura 2.7 – Simulação de uma parcela da floresta amazônica utilizando o modelo DART. ....	23
Figura 2.8 – Procedimento de inversão de modelos de transferência radiativa com Redes Neurais Artificiais (ANN). ....	26
Figura 2.9 – Estrutura genérica de uma Rede Neural Artificial (ANN) com múltiplas camadas. ....	27
Figura 2.10 – Fluxograma para estimativa da concentração de clorofila utilizando modelagem de transferência radiativa e imagens hiperespectrais.....	29
Figura 3.1 – Localização da área de estudo.....	34
Figura 3.2 – Sensor hiperespectral ProSpecTIR-VS. ....	35
Figura 3.3 – Estilingue utilizado para a coleta de folhas do topo do dossel.....	41
Figura 3.4 – Acessório Plant Probe acoplado ao aparato Leaf Clip, utilizado para medir a reflectância bidirecional de folhas.....	41
Figura 3.5 – Receptor GPS Hiper+ acoplado a uma antena extensível de 5 metros para melhorar a captação do sinal. ....	42
Figura 3.6 – Obtenção do ângulo azimutal ao centro da parcela por meio de uma bússola comum.....	43
Figura 3.7 – Exemplo de marcação de uma árvore que dominava o dossel no interior da parcela. ....	44

Figura 4.1 – Funções de filtro das bandas do satélite WorldView-3.....	51
Figura 4.2 – Similaridade mútua entre dois <i>pixels</i> .....	57
Figura 4.3 – Distância de Jeffreys-Matusita (JM) (Eq. 1) entre as regiões $R_A$ e $R_B$ , calculada com os vetores de média ( $M_A$ ; $M_B$ ) e as matrizes de covariância ( $C_A$ ; $C_B$ ). .....	58
Figura 4.4 – Propriedades ópticas do subdossel verde e seco com 2,5 m ( $\pm 0,5$ m) de altura, galhos e serapilheira utilizados nas simulações do modelo DART. .....	61
Figura 5.1 – Exatidão média, bandas e IVs selecionados durante o processo de classificação. ....	72
Figura 5.2 – Exatidão média de classificação obtida com bandas simuladas do sensor WorldView-3.....	73
Figura 5.3 – Exatidão de classificação obtida com dados hiperespectrais e WorldView- 3.....	74
Figura 5.4 – (a)-(b) Média (linhas em negrito) $\pm 1$ envelopes de desvio padrão da resposta espectral das espécies arbóreas. Um offset de 0,5 foi aplicado ao espectro de cada espécie para melhorar a visualização. (c) Resposta espectral média das espécies estudadas.....	76
Figura 5.5 – Variabilidade espectral e de exatidão de classificação das espécies arbóreas. ....	78
Figura 5.6 – Resultados do método de segmentação aplicado à classificação orientada a objetos. ....	82
Figura 5.7 – Mapas de espécies arbóreas produzidos pelo método proposto.....	84
Figura 5.8 – Desvio quadrático médio (RMSD) (%) entre a resposta espectral experimental e simulada de sete espécies arbóreas da área de estudo. ....	86
Figura 5.9 – Resposta espectral experimental e simulada de sete espécies arbóreas da área de estudo com a respectiva média e envelopes de $\pm 1$ desvio padrão. ....	88
Figura 5.10 – Gráfico de dispersão entre o conteúdo de clorofila ( $C_{ab}$ ) e o índice de vegetação MCARI.....	89

Figura 5.11 – Variabilidade do conteúdo de clorofila ( $C_{ab}$ ) que originou os 20 espectros simulados mais semelhantes a cada pixel das espécies arbóreas (menor RMSD, Equação 4.8). .....	90
Figura 5.12 – Importância de bandas do visível/infravermelho próximo estimadas pela diminuição média do índice de Gini (MDG) de sete espécies arbóreas da área de estudo. ....	92
Figura 5.13 – Separabilidade espectral intra e interespecífica das espécies arbóreas. ...	94
Figura 5.14 – Variação da resposta espectral das simulações DART após a variação de um parâmetro por vez e mantendo os outros constantes (análise de sensibilidade one-at-a-time (OAT-SA)) (refira-se à Tabela 4.3). ....	96
Figura 5.15 – Variação dos índices de sensibilidade.....	97
Figura 5.16 – Comparação entre imagens hiperespectrais reais e simuladas pelo modelo DART. ....	99



## LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 – Parâmetros de entrada do modelo de transferência radiativa PROSPECT-5. .....	18
Tabela 3.1 - Especificações do instrumento hiperespectral.....	34
Tabela 3.2 – Características da imagem do sensor orbital WorldView-3 (WV-3).....	37
Tabela 3.3 – Lista das espécies, número de indivíduos, pixels, número médio de pixels por copa e mínimo e máximo Diâmetro à Altura do Peito (DAP). Em negrito, destaque para as espécies com mais de 10 indivíduos amostrados. .....	38
Tabela 3.4 – Lista das espécies, número de indivíduos e número de folhas amostrado para coleta de dados espectrais.....	39
Tabela 3.5 - Lista das espécies, altura total, altura comercial, diâmetro da copa, Diâmetro à Altura do Peito (DAP), distância ao centro e ângulo azimutal das árvores que dominavam o dossel da parcela circular com raio de 30 metros.....	45
Tabela 4.1 – Índices de vegetação utilizados no trabalho, juntamente com suas respectivas fórmulas e referências bibliográficas, classificados de acordo com Roberts et al. (2011). .....	48
Tabela 4.2 - Lista das espécies, número de indivíduos e pixel nas imagens hiperespectral e WorldView-3 (WV-3). .....	52
Tabela 4.3 – Parâmetros DART + PROSPECT-5, suas faixas e incrementos de variação e natureza, utilizados para a construção da Look-Up-Table (LUT).....	64
Tabela 5.1 – Exatidão média de classificação (%) para 100 mapas de espécies arbóreas, produzidos com diferentes copas de treinamento e teste, utilizando os métodos Análise Discriminante Linear (LDA), <i>Support Vector Machines</i> com <i>kernel</i> linear (L-SVM), <i>kernel</i> Função de Base Radial (RBF-SVM) e <i>Random Forest</i> (RF). Os códigos das espécies foram disponibilizados na Tabela 4.2. ....	83



## LISTA DE SIGLAS E ABREVIATURAS

1D	Unidimensional
3D	Tridimensional
AG	<i>Astronium graveolens</i>
ALA	Average leaf angle
ANN	Artificial neural network
ANOVA	Analysis of variance
AP	<i>Aspidosperma polyneuron</i>
ARI	Anthocyanin reflectance index
ASD	Analytical spectral devices
AVIRIS	Airborne visible/infrared imaging spectrometer
C <sub>ab</sub>	Clorofila a+b
CARI	Chlorophyll absorption reflectance index
CAVIS	Clouds, aerosol, vapor, ice, snow
CL	<i>Cariniana legalis</i>
C <sub>m</sub>	Conteúdo de matéria seca
CRI-1	Carotenoid reflectance index 1
CRI-2	Carotenoid reflectance index 2
C <sub>w</sub>	Espessura equivalente de água
C <sub>wa</sub>	Clima subtropical úmido
C <sub>xc</sub>	Carotenoides
DAP	Diâmetro à altura do peito
DART	Discrete anisotropic radiative transfer
DBF	Density of branches per voxel
DG-AComp	DigitalGlobe atmospheric compensation algorithm

DLF	Density of leaves per voxel
DS	<i>Diatenopteryx sorbifolia</i>
ENVI	Environment for visualizing images
EO-1	Earth observation 1
EVI	Enhanced vegetation index
FA	Floresta atlântica
FDRB	Função de distribuição da reflectância bidirecional
FES	Floresta estacional semidecidual
FLAASH	Fast line-of-sight atmospheric analysis of spectral hypercubes
FOTO	Fourier transform textural ordination
FOV	Field of view
GLT	Geometric look-up table
GNSS	Sistemas globais de navegação por satélite
GPS	Global positioning system
GRART	Modelo de transferência radiativa para dosséis descontínuos regulares
HC	<i>Hymenaea courbaril</i>
IAF	Índice de área foliar
IGM	Internal geometry map
IMU	Inertial measurement unit
INS	Inertial navigation system
ITC	Individual tree crown
IV	Índice de vegetação
JM	Jeffreys-matusita
K-M	Kubelka-munk
LAD	Linear discriminant analysis
LAD	Leaf angle distribution
LER	Laboratório de espectroscopia de reflectância

LiDAR	Light detection and ranging
L-SVM	Linear <i>Support Vector Machines</i>
LUT	Look-up table
MCARI	Modified CARI
MDA	Mean decrease in accuracy
MDG	Mean Decrease in Gini
MTR	Modelo de transferência radiativa
N	Parâmetro estrutural da folha
NDII	Normalized difference infrared index
NDLI	Normalized difference lignin index
NDNI	Normalized difference nitrogen index
NDVI	Normalized difference vegetation index
NDWI	Normalized difference water index
OAT-SA	One-at-a-time sensitivity analysis
OBF	Optical branch factor
OGF	Optical ground factor
PAI	Plant area index
PAN	Pancromático
pCells	Proporção de células preenchidas no interior da copa
PL	<i>Pachystroma longifolium</i>
PRI	Photochemical reflectance index
PROSPECT	Model of leaf optical properties spectra
PSND	Pigment sensitive normalized difference
PSRI	Plant senescence reflectance index
RAMI	Radiation transfer model intercomparison
RBF-SVM	Radial basis function <i>Support Vector Machines</i>
RBMC	Rede brasileira de monitoramento contínuo

REM	Radiação eletromagnética
RENDVI	Red edge normalized difference vegetation index
REP	Red edge position
RF	<i>Random forest</i>
RMSD	Root mean square deviation
RSG	Reserva de Santa Genebra
SAIL	Scattering by arbitrarily inclined leaves
SAM	Spectral angle mapper
SIPI	Structurally insensitive pigment index
SNR	Signal-to-noise ratio
SR <sub>red/green</sub>	Simple ratio red/green
SVM	<i>Support Vector Machines</i>
SWIR	Shortwave infrared
TOA	Top-of-atmosphere
TOC	Top-of-canopy
UNICAMP	Universidade Estadual de Campinas
UTM	Universal transverse mercator
VARI	Visible atmospherically resistant index
VIg	Visible green index
VNIR	Visible to near infrared
WV-3	WorldView-3

## LISTA DE SÍMBOLOS

D	Diferença de amplitude
$\theta$	Diferença angular
$\gamma_a$	Coefficiente de absorção
$\gamma_s$	Coefficiente de espalhamento
$\Theta$	Ângulo de espalhamento
$I_{\uparrow}, I_{\downarrow}$	Fluxo de luz difusa nas direções ascendente e descendente, respectivamente
$R_{mes}$	Reflectância medida
$R_{sim}$	Reflectância simulada
$\rho$	Reflectância
C	Parâmetro de penalização
$\gamma_{RBF}$	Parâmetro gamma do <i>kernel</i> radial basis function
$n_{tree}$	Número de árvores
$m_{try}$	Número de variáveis



## SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO .....	1
1.1. Hipóteses .....	3
1.2. Objetivo principal.....	4
1.3. Objetivos específicos .....	4
2 FUNDAMENTAÇÃO TEÓRICA .....	5
2.1. Identificação de espécies arbóreas tropicais por sensoriamento remoto.....	5
2.1.1. Nível foliar .....	5
2.1.2. Nível de dossel .....	8
2.2. Química do dossel e sua relação com a identificação de espécies.....	11
2.3. Estimativas da química do dossel por sensoriamento remoto.....	12
2.3.1. Modelagem de transferência radiativa .....	12
2.3.1.1. Princípios físicos e bases conceituais.....	13
2.3.1.2. Modelos de Transferência Radiativa (MTRs).....	15
2.3.1.2.1. PROSPECT .....	17
2.3.1.2.2. DART .....	20
2.3.2. Modelagem inversa .....	24
2.3.2.1. Técnicas de inversão .....	24
2.3.2.1.1. Otimização iterativa .....	24
2.3.2.1.2. Abordagens <i>Look-Up Table</i> .....	25
2.3.2.1.3. Redes Neurais Artificiais .....	25
2.3.2.2. Exemplos de aplicação das técnicas de inversão .....	27
2.3.3. Modelagem direta.....	30
3 MATERIAL .....	33
3.1. Área de estudo.....	33
3.2. Imagens hiperespectrais .....	33
3.3. Imagens WorldView-3 (WV-3) .....	35
3.4. Levantamento de copas de árvores individuais.....	36
3.5. Dados espectrais ao nível foliar .....	39

3.5.1. Coleta de folhas do topo do dossel e medição da reflectância.....	39
4 MÉTODOS .....	47
4.1. Discriminação e mapeamento de espécies arbóreas.....	47
4.1.1. Pré-processamento dos dados de sensoriamento remoto .....	47
4.1.1.1. Imagens hiperespectrais .....	47
4.1.1.1.1. Índices de vegetação.....	48
4.1.1.1.2. Seleção de bandas.....	49
4.1.1.1.3. Simulação das bandas do satélite WorldView-3 .....	50
4.1.1.2. Imagens WorldView-3 .....	51
4.1.2. Experimentos de classificação ao nível de <i>pixel</i> .....	52
4.1.2.1. Seleção de amostras de treinamento e teste .....	52
4.1.2.2. Métodos estatísticos de classificação .....	53
4.1.2.2.1. Classificação de imagens hiperespectrais .....	53
4.1.2.2.2. Classificação de imagens WorldView-3 .....	54
4.1.3. Variabilidade espectral.....	55
4.1.4. Produção de mapas de espécies arbóreas .....	55
4.1.4.1. Segmentação de imagens .....	56
4.1.4.2. Avaliação da exatidão do mapeamento .....	59
4.2. Simulação da resposta espectral de espécies arbóreas .....	59
4.2.1. Modelagem de transferência radiativa .....	60
4.2.2. Geração da <i>Look-Up-Table</i> .....	62
4.2.3. Análise de sensibilidade .....	65
4.2.4. Comparação entre dados reais e simulados.....	66
4.2.4.1. Filtragem e extração de espectros para a comparação .....	66
4.2.5. Definição de métricas para mensuração da similaridade espectral .....	68
4.2.5.1. Importância de atributos .....	68
4.2.5.2. Separabilidade espectral .....	70
5 RESULTADOS E DISCUSSÃO .....	71
5.1. Discriminação e mapeamento de espécies arbóreas.....	71
5.1.1. Classificação e variabilidade espectral ao nível de <i>pixel</i> .....	71
5.1.2. Mapas de espécies arbóreas .....	80

5.2. Simulação da resposta espectral de espécies arbóreas .....	85
5.2.1. Similaridade espectral e inversão da <i>Look-Up-Table</i> .....	85
5.2.2. Importância de atributos e separabilidade espectral.....	91
5.2.3. Análise de sensibilidade .....	93
5.2.4. Simulação de imagens hiperespectrais.....	98
6 CONCLUSÕES .....	101
REFERÊNCIAS BIBLIOGRÁFICAS .....	103



## 1 INTRODUÇÃO

A Floresta Atlântica (FA) possui apenas 15% de sua cobertura original (1,3mi Km<sup>2</sup>) (RIBEIRO et al., 2009; SOS/INPE, 2015) e é considerada o bioma mais ameaçado do Brasil. Embora seja reconhecida internacionalmente como um *hotspot* da biodiversidade, pelas altas taxas de endemismo e por abrigar de 1 a 8% das espécies de animais e plantas terrestres (MYERS et al., 2000), a FA continua sendo desmatada a uma taxa de aproximadamente 18.000 ha por ano (SOS/INPE, 2015). Essa situação é ainda mais crítica no estado de São Paulo que perdeu 86% de suas áreas de floresta (SOS/INPE, 2015), sendo a Floresta Estacional Semidecidual (FES) a formação com o menor percentual restante (5,7 %; SOS/INPE, 2015). Estratégias de conservação da FA, que incluem, por exemplo, o estabelecimento de novas áreas protegidas e iniciativas de restauração, dependem de informações de alta qualidade sobre seus remanescentes. Em especial, a localização de árvores matrizes, que fornecem sementes para a produção de mudas, pode reduzir custos de trabalhos de campo e elevar a diversidade genética intraespecífica (LESSICA; ALLENDORF, 1999), favorecendo iniciativas de recomposição da vegetação natural.

O mapeamento de espécies arbóreas ao nível de copas individuais (ITC, do inglês *Individual Tree Crown*) em florestas tropicais vem sendo realizado por sensoriamento remoto hiperespectral de alta resolução espacial ( $pixel \leq 1m$ ) (CLARK et al., 2005; FÉRET; ASNER, 2012; FÉRET; ASNER, 2013; AMARAL et al., 2015; BALDECK et al., 2015). Sensores hiperespectrais medem a radiação solar refletida pelo dossel em centenas de bandas estreitas e, assim, permitem a identificação de variações sutis na resposta espectral das árvores, o que determina sua detecção remota. Entretanto, a discriminação de espécies em ambientes tropicais apresenta uma série de indagações técnicas. Questiona-se, por exemplo, se a variabilidade intraespecífica é significativamente menor do que a interespecífica (ZHANG et al., 2006), pressuposto este, básico para a aplicação de métodos estatísticos de classificação. Pouco se sabe, também, acerca do desempenho desses métodos, principalmente em florestas de alta variabilidade espectral como a FES, onde indivíduos da mesma espécie podem apresentar

padrões distintos de deciduidade, dependendo de sua idade e condições ambientais (MORELLARO, 1991).

Métodos de processamento de imagens capazes de extrair informações taxonômicas de dados hiperespectrais se encontram em estágios iniciais de desenvolvimento. Notadamente, a produção de mapas de espécies em ambientes de floresta tropical é um desafio, visto que centenas de espécies compõe o dossel e um alto grau de incerteza é obtido ao se classificar todos os *pixels* de uma imagem. Avanços nessa área podem gerar informações valiosas a pesquisadores e gestores florestais, contribuindo para levantamentos florísticos e monitoramento de espécies de interesse. Investigações anteriores mostraram que abordagens de classificação orientada a objetos elevam a exatidão do mapeamento (CLARK et al., 2005; FÉRET; ASNER, 2013), porém, essas abordagens requerem o delineamento automático de copas, o que é extremamente difícil em florestas tropicais devido à complexidade estrutural do dossel (TOCHON et al., 2015). Desse modo, a produção de mapas de espécies em florestas de alta diversidade, por meio da utilização de abordagens baseadas em classificação orientada a objetos, até o momento, ainda não foi realizada.

Sensores hiperespectrais operam em diferentes faixas do espectro eletromagnético. Grande parte dos estudos utilizaram sensores com cobertura no visível e infravermelho próximo (VNIR, 390-1000 nm; do inglês *visible to near infrared*) (p.e. FÉRET; ASNER, 2013; ZHANG et al., 2006). Não obstante, avanços na tecnologia de sensoriamento remoto permitiram a aquisição de dados na região do infravermelho de ondas curtas (SWIR, 1000-2500 nm; do inglês *shortwave infrared*), em bandas espectrais relativamente estreitas ( $\leq 10$  nm). Isso pode elevar a exatidão da classificação de espécies pelo realce de diferenças em constituintes foliares não pigmentados como água, nitrogênio, celulose e lignina (KOKALY et al., 2009). Além disso, capacidades de sensoriamento na região do SWIR foram recentemente incorporadas a plataformas orbitais de alta resolução espacial, como o satélite WorldView-3 (WV-3), abrindo novas oportunidades para o mapeamento de árvores.

A detecção de espécies arbóreas com dados de sensoriamento remoto é viável, pois as mesmas apresentam variações significativas em seu comportamento

espectral. Tais variações são induzidas por parâmetros bioquímicos e biofísicos da copa, geralmente relacionados às folhas, e podem ser utilizados para o mapeamento de espécies ou fitofisionomias (p.e. WESSMAN et al., 1998; FUENTES et al., 2001; KOKALY et al., 2003). Entretanto, a estimativa desses parâmetros não é uma tarefa simples. Embora a resposta espectral das árvores esteja relacionada a características da copa, efeitos de iluminação, da reflectância do substrato e da atmosfera também contribuem para a variabilidade espectral do dossel. Desse modo, é necessário aprimorar o conhecimento acerca dos fatores que influenciam o sinal eletromagnético registrado por sensores remotos, o que vem sendo feito com sucesso pela utilização de Modelos de Transferência Radiativa (MTRs).

MTRs são modelos físicos capazes de descrever mecanismos de transporte de fótons que agem no interior do dossel (folhas, ramos e galhos) e dos elementos localizados abaixo do mesmo (sub-bosque, serapilheira, solo, etc.), sendo utilizados para simular a resposta espectral da vegetação. Particularmente, MTRs tridimensionais (3D) são capazes de lidar de forma explícita com a estrutura do dossel e, em conjunto com imagens hiperespectrais, tem sido utilizados para extração de atributos químicos de áreas de floresta (p.e. MALENOVSKÝ et al., 2013). Tal abordagem é baseada em técnicas de inversão que requerem fundamentalmente a simulação acurada da resposta espectral do dossel. Pouco se sabe, todavia, sobre a capacidade de MTRs em reproduzir dados hiperespectrais adquiridos sobre florestas tropicais, tampouco acerca do desempenho de tais modelos na simulação da reflectância de espécies arbóreas.

### **1.1. Hipóteses**

Esta pesquisa é baseada nas seguintes hipóteses:

- A variação espectral intraespecífica, ao nível de dossel, de espécies arbóreas da Floresta Estacional Semidecidual é significativamente menor do que a interespecífica;
- A exatidão de classificação de espécies arbóreas da Floresta Estacional Semidecidual está diretamente relacionada à diferença entre a variabilidade intra e interespecífica;

- A resposta espectral ao nível de dossel de espécies arbóreas da Floresta Estacional Semidecidual pode ser simulada de forma acurada por modelagem de transferência radiativa em três dimensões, a ponto de não alterar a variabilidade intra e interespecífica original das espécies.

## **1.2. Objetivo principal**

O objetivo principal desta pesquisa foi explorar a utilização de dados reais e simulados de sensoriamento remoto multi e hiperespectral para mapear e classificar espécies arbóreas da FES.

## **1.3. Objetivos específicos**

Especificamente pretendeu-se:

- i. Avaliar o desempenho de métodos estatísticos de classificação na discriminação de espécies arbóreas da área de estudo;
- ii. Identificar regiões e bandas espectrais, no intervalo de 450 a 2400 nm, propícias à classificação das espécies;
- iii. Avaliar a utilização de índices de vegetação de bandas estreitas na discriminação das espécies;
- iv. Quantificar a variabilidade espectral intra e interespecífica, bem como sua influência, na classificação das espécies;
- v. Desenvolver um método para o mapeamento automático das espécies ao nível de árvores individuais;
- vi. Desenvolver uma abordagem de simulação da resposta espectral das espécies ao nível de dossel a partir da utilização de modelagem de transferência radiativa em três dimensões;
- vii. Comparar a resposta espectral simulada e medida das espécies.

## **2 FUNDAMENTAÇÃO TEÓRICA**

Nesta seção serão abordados os aspectos conceituais e teóricos que permeiam os objetivos desta pesquisa.

### **2.1. Identificação de espécies arbóreas tropicais por sensoriamento remoto**

No que tange à identificação de espécies, a potencialidade do sensoriamento remoto foi verificada na década de 1980, quando as primeiras imagens com alta resolução espectral foram adquiridas (GOETZ; VANE, 1985). Desde então, estudos têm sido realizados para se obter informações sobre a possível utilidade de dados de reflectância na discriminação de espécies e mapeamento de fitofisionomias. Essa utilidade é, entretanto, questionada devido à elevada similaridade existente entre espectros de diferentes tipos de plantas. Ao nível foliar, segundo Gates et al. (1965), a interação da radiação eletromagnética (REM) com a vegetação é controlada basicamente por três parâmetros: concentração de pigmentos, estrutura e quantidade de água. Sendo assim, diferentes espécies apresentam comportamento espectral muito parecido. Na realidade, a condição básica que deve ser satisfeita é que a variabilidade intraespecífica seja significativamente menor do que a interespecífica. Em florestas tropicais, com alta diversidade florística, a verificação dessa condição é primordial para avaliar a potencialidade de dados de reflectância, em particular dados de imageamento hiperespectral, na discriminação de espécies. Nesse contexto, muitos estudos se preocuparam em avaliar a variabilidade intra e interespecífica ao nível foliar e de dossel (e.g. CASTRO-ESSAU et al., 2006; CLARK et al., 2005). É válido destacar que, ao nível de dossel, investigações dessa natureza exigem, além do caráter hiperespectral, dados com resolução espacial fina o suficiente para permitir a visualização das copas, individualizando, assim, a resposta espectral das árvores.

#### **2.1.1. Nível foliar**

Desde a verificação da potencialidade do sensoriamento remoto hiperespectral em estudos botânicos, ecológicos e fitossociológicos, pesquisas vêm sendo realizadas para entender a variabilidade espectral de plantas. Price (1994) em seu trabalho intitulado “*How unique are spectral signatures? – Quão peculiares são as assinaturas espectrais?*” sugere que diferentes espécies vegetais apresentam

comportamento espectral muito parecido e que sua identificação é comprometida pela variação intraespecífica. Nesse trabalho, o autor propõe duas métricas para quantificar a variabilidade espectral. A primeira delas, denominada  $D$ , representa a diferença de amplitude entre dois espectros ( $S_1$  e  $S_2$ ) no intervalo  $\lambda_a$  a  $\lambda_b$ , calculada como:

$$D = \left[ \frac{1}{\lambda_b - \lambda_a} \int_{\lambda_a}^{\lambda_b} [S_1(\lambda) - S_2(\lambda)]^2 d\lambda \right]^{1/2} \quad (2.1)$$

A segunda métrica, chamada  $\theta$ , corresponde à diferença angular entre dois espectros e está relacionada às variações na forma dos mesmos. Para o par  $[S_1, S_2]$ ,  $\theta$  é dado por:

$$\theta_{S_1, S_2} = \cos^{-1} \left( \frac{\int_{\lambda_a}^{\lambda_b} S_1(\lambda) S_2(\lambda) d\lambda}{\left[ \int_{\lambda_a}^{\lambda_b} S_1(\lambda)^2 d\lambda \right]^{1/2} \left[ \int_{\lambda_a}^{\lambda_b} S_2(\lambda)^2 d\lambda \right]^{1/2}} \right) \quad (2.2)$$

$D$  e  $\theta$  são amplamente utilizados em estudos de variabilidade espectral de plantas para quantificar as diferenças entre todos os pares possíveis de medidas, ou seja,  $n(n-1)/2$  onde  $n$  é o número de medidas. Estudar a variabilidade das espécies de plantas em ambientes tropicais com alta diversidade é importante, pois a separabilidade interespecífica pode não ser suficiente para a discriminação. No âmbito de florestas tropicais, existem alguns trabalhos que já discutiram essa questão.

Cochrane (2000) utilizou um espectrorradiômetro, com cobertura no intervalo de 450-950 nm, para obter a reflectância de folhas de 11 espécies arbóreas da Amazônia e analisou as variabilidades intra e interespecíficas por meio das métricas  $D$  (Equação 2.1) e  $\theta$  (Equação 2.2). Ao coletar 325 amostras de 25 árvores de Mogno (*Swietenia macrophylla*), oriundas de galhos superiores e inferiores, o autor comenta que a posição das folhas na árvore influenciou pouco seu comportamento espectral, e baixos valores de  $D$  e  $\theta$  foram obtidos. Isso também foi verificado para folhas de uma mesma árvore. No entanto, quando o espectro médio de todas as amostras de Mogno foi utilizado como referência na

comparação com outras espécies,  $D$  e  $\theta$  foram significativamente maiores, variando de acordo com a espécie.

Castro-Esau et al. (2006) investigaram o impacto da variabilidade espectral, quantificada por  $D$  e  $\theta$ , na classificação de 50 espécies arbóreas. Os autores mediram a reflectância de folhas do topo do dossel de até cinco árvores por espécie, de sítios distintos e em duas estações do ano. Para um mesmo sítio e época de coleta, a variabilidade intraespecífica foi significativamente menor do que a interespecífica, resultando em uma exatidão de classificação superior a 80%. Ao se considerar amostras oriundas da mesma espécie, mas obtidas em épocas distintas, a exatidão não ultrapassou 50%. Ainda sobre esse estudo, é interessante ressaltar que o erro de classificação variou de acordo com o algoritmo e o número de bandas selecionadas. Esse erro também foi afetado pelo número de espécies, atingindo valores de 14% para cinco e 23% para cinquenta espécies.

Hesketh e Sánchez-Azofeifa (2012) investigaram a variação espectro-temporal de espécies arbóreas tropicais ao nível foliar e seus impactos na classificação. Os autores coletaram dados da reflectância espectral de folhas de 47 espécies arbóreas em dois períodos, no pico da estação chuvosa e no início da estação seca. Os resultados foram similares aos de Castro-Esau et al. (2006). Enquanto a classificação intra-estação atingiu valores de exatidão superiores a 90%, entre estações esse valor não passou de 16%, o que ressalta a dificuldade de classificar amostras oriundas da estação chuvosa, tendo como conjunto de treinamento amostras da estação seca.

No Brasil, há poucos registros de estudos que buscaram analisar a variabilidade espectral de espécies arbóreas. Entre eles, destaca-se o de Ferreira et al. (2013) que buscou quantificar as variações intra e interespecíficas da reflectância de folhas de sete espécies arbóreas da Floresta Atlântica. As métricas  $D$  e  $\theta$  apresentaram resultados com diferença estatística significativa entre amostras de árvores da mesma espécie e de espécies distintas. Com um procedimento de seleção de bandas e um classificador paramétrico, os autores atingiram 96% de exatidão global com a base de dados utilizada.

Os estudos apresentados até aqui se concentraram na investigação da variabilidade espectral e identificação de espécies ao nível foliar. No entanto, há um grande interesse na detecção de árvores em escalas geográficas mais amplas. Nesse contexto, surge a seguinte indagação: quão útil é o conhecimento sobre a variabilidade espectral foliar na detecção de espécies do dossel florestal? Castro-Esau et al. (2006) refletiram sobre essa questão e argumentaram que estudos ao nível foliar são importantes, pois a reflectância da copa é dominada pela quantidade de radiação que interage com as folhas. Sendo assim, estudos ao nível foliar podem parcialmente explicar as variabilidades intra e interespecíficas das espécies.

### **2.1.2. Nível de dossel**

Diferentemente do nível foliar, ao nível de dossel, a interação da REM com a vegetação depende da combinação de muitas variáveis. Dentre elas, além dos próprios elementos da vegetação (folhas, galhos, cascas, frutos, sementes, etc.), podemos citar as propriedades espectrais do substrato (serapilheira, solo, etc.), os parâmetros biofísicos (Índice de Área Foliar (IAF); Distribuição Angular das Folhas (LAD, do inglês *Leaf Angle Distribution*)) e fatores de natureza geométrica (ângulos de iluminação e visada) (PONZONI et al., 2012). Essas variáveis, em conjunto com a complexidade estrutural do dossel de florestas tropicais, torna a identificação de espécies desafiadora. A diferença de altura entre as árvores e forma das copas produz proporções distintas de *pixels* iluminados e sombreados, principalmente em dados de alta resolução espacial. Em imagens hiperespectrais, isso dificulta a extração de espectros representativos das espécies, uma vez que, no interior da copa de uma única árvore a variabilidade espectral pode ser alta.

A identificação de copas individuais em florestas tropicais com dados de sensoriamento remoto experimentou grande avanço, com a aquisição de dados hiperespectrais de alta resolução espacial. Imagens com *pixels* menores do que 5 metros proporcionam a individualização das copas das árvores, favorecendo a obtenção de *pixels* relativamente puros. O trabalho de Clark et al. (2005) foi o primeiro a utilizar esse tipo de dado para classificar espécies arbóreas em florestas tropicais, abrindo caminho para o desenvolvimento dessa linha de pesquisa. Os autores utilizaram dados hiperespectrais aerotransportados, obtidos sobre uma floresta costarriquenha, para identificar sete espécies arbóreas. Analisaram a

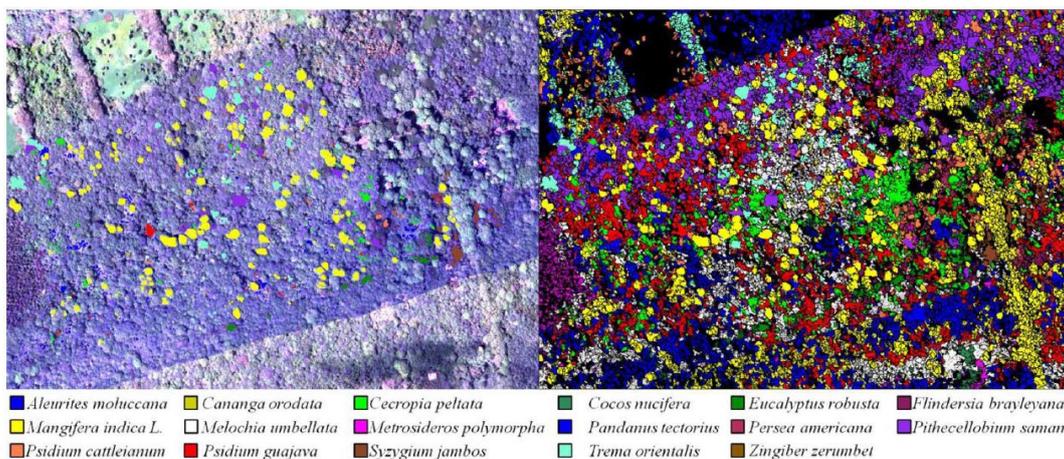
variabilidade espectral das espécies ao nível de folha, *pixel* e copa. A variação intra e interespecífica foi quantificada pelo ângulo ( $\theta$ , Equação 2.2) e distância euclidiana ( $D$ , Equação 2.1) entre pares de espectros. Os resultados da análise revelaram que, ao se utilizar o ângulo espectral, as variações intra e interespecífica possuíam diferença estatística significativa ao longo de todo espectro nos níveis de folha e *pixel*. No entanto, a variação da resposta espectral média entre copas mostrou-se pronunciada na região do infravermelho próximo. Alguns métodos de classificação foram testados: análise discriminante linear (LDA, do inglês *Linear Discriminant Analysis*, Fisher (1936)), mapeador de ângulo espectral (SAM, do inglês *Spectral Angle Mapper*) e máxima verossimilhança (MAXVER). LDA obteve o melhor desempenho, atingindo 90,2% de exatidão global após procedimento de seleção de bandas.

Zhang et al. (2006) ao analisarem a variação intra e interespecífica de 17 árvores tropicais, constataram que as diferenças entre espécies nem sempre seguem uma distribuição normal, como assumido pelas classificações paramétricas de Clark et al. (2005). Desse modo, eles sugerem a transformada *wavelet* (BRUCE et al., 2001) como alternativa aos métodos paramétricos. Os autores argumentam que essa técnica minimiza as variações intraespecíficas favorecendo a discriminação de espécies ao nível de dossel. Além dos dados transformados por *wavelets*, Zhang et al. (2006) efetuaram a primeira derivada dos espectros para analisar a capacidade da técnica na diferenciação das árvores estudadas. Constataram que a primeira derivada acentuou pequenas variações entre os *pixels* das copas e consequentemente aumentou a variabilidade intraespecífica. Por fim, os autores sugerem que a classificação de muitas espécies em ambientes tropicais é impraticável, mas destacam o potencial de imagens hiperespectrais de alta resolução espacial na identificação de grupos taxonômicos ou espécies previamente selecionadas.

Féret e Asner (2013) analisaram o desempenho de classificadores paramétricos e não-paramétricos na identificação de espécies em floresta tropical com imagens hiperespectrais. A variabilidade ao nível de dossel foi analisada com a distância de Bhattacharyya (KAILATH, 1967), bem como  $D$  (Equação 2.1) e  $\theta$  (Equação 2.2). Os autores sugerem que a distância de Bhattacharyya, por considerar a matriz de covariância entre as classes, é mais adequada do que  $D$  e  $\theta$  para

quantificar a separabilidade espectral entre espécies. Destacam também a potencialidade do uso do classificador *Support Vector Machines* (MELGANI; BRUZZONE, 2004) para lidar com o problema em questão. Ainda sobre esse trabalho, é interessante destacar que os autores utilizaram uma abordagem baseada em objetos para obter um mapa da distribuição espacial de 17 espécies arbóreas (Figura 2.1). Essa abordagem consiste em uma etapa de segmentação pré-classificação com objetivo de delinear as copas das árvores e, assim, de certa forma, individualizar a resposta espectral das espécies.

Figura 2.1 – Mapa de espécies arbóreas.



(Esquerda) Composição colorida (R=646 nm; G=560,7 nm; B= 447nm) de imagem hiperespectral de alta resolução espacial (0,56 m), cobrindo uma área de 70 ha de uma floresta tropical do Havaí. Os polígonos coloridos representam árvores individuais manualmente delimitadas após trabalho de campo e foram utilizados como amostras de treinamento para classificações. (Direita) Mapa da distribuição espacial de 17 espécies arbóreas obtidas após a classificação das imagens hiperespectrais.

Fonte: Féret e Asner (2013).

Ao nível orbital, há poucos registros de trabalhos que buscaram lidar com variabilidade espectral de árvores tropicais para fins de classificação. Isso advém da escassez de dados hiperespectrais em boas condições (baixa cobertura de nuvens) adquiridos sobre florestas tropicais. Além disso, normalmente a relação sinal/ruído desses dados é baixa e a resolução espacial também não é suficiente para individualizar as copas. Apesar dessas limitações, Papeş et al. (2010) utilizaram imagens do sensor *Hyperion* do satélite EO-1 (UNGAR et al., 2003) para classificar árvores de cinco gêneros de uma floresta da Amazônia peruana. Por meio de uma imagem *QuickBird* ( $pixel < 2\text{ m}$ ) e dados de campo, os autores

identificaram 42 árvores, das quais 31 cobriam mais de 50% de um *pixel* Hyperion (*pixel*=30 m). Para esse último conjunto, com 25 bandas selecionadas os autores obtiveram 100 % de exatidão em classificações de imagens das estações seca e chuvosa. Tal sucesso foi atribuído ao pequeno número de espécies selecionado e às significativas diferenças interespecíficas.

## **2.2. Química do dossel e sua relação com a identificação de espécies**

Como destacado anteriormente, a detecção remota de espécies arbóreas é viável, pois as mesmas apresentam variações significativas em seu comportamento espectral. Tais variações são induzidas por parâmetros bioquímicos e biofísicos da copa, geralmente relacionados às folhas. Esses parâmetros são também conhecidos como características funcionais por exercerem diferentes funções na planta. Por exemplo, pigmentos fotossintetizantes (clorofilas, carotenoides, antocianinas, etc.) e nitrogênio participam do crescimento vegetal (TAIZ; ZEIGER, 2010). Outras substâncias, como celulose e lignina, são responsáveis pela estrutura da folha, conferindo-las resistência e defesa ao ataque de herbívoros (WRIGHT et al., 2004). Investigações recentes mostraram que as características funcionais de florestas tropicais estão organizadas taxonomicamente (ASNER et al., 2014) ou diretamente relacionadas à composição de espécies (FYLLAS et al., 2009), sugerindo que seu monitoramento pode trazer informações importantes sobre a diversidade funcional (JETZ et al., 2016). A diversidade funcional, i.e., uma vasta gama de propriedades das plantas que controlam o funcionamento de um ecossistema (TILMAN, 2001), desempenha papel importante nos ciclos biogeoquímicos (DÍAZ; CABIDO, 2001), como os ciclos do carbono e da água. Além de estarem relacionados à diversidade funcional, os atributos químicos das folhas podem ser utilizados para a discriminação de espécies.

O trabalho pioneiro de Wessman et al. (1988) mostrou que espécies arbóreas estão espacialmente distribuídas de acordo com a porcentagem de lignina da copa, a qual foi estimada com dados de um sensor hiperespectral aerotransportado. Fuentes et al. (2001) utilizaram a concentração de pigmentos e água do dossel de florestas boreais, extraídos com imagens do sensor AVIRIS (GREEN et al., 1998) por meio de índices de vegetação (IVs), para mapear tipologias florestais. Kokaly et al. (2003), com dados desse mesmo sensor e uma abordagem baseada nas feições de absorção da clorofila e água líquida foliar, mapearam com sucesso

fitofisionomias florestais do parque de Yellowstone (EUA). Esses exemplos sugerem uma forte relação entre os atributos químicos do dossel e seu comportamento espectral.

### **2.3. Estimativas da química do dossel por sensoriamento remoto**

A estimativa de parâmetros bioquímicos e biofísicos da vegetação com dados de sensoriamento remoto segue geralmente duas abordagens. A primeira delas, conhecida como empírica, utiliza métodos estatísticos (regressão) para relacionar variáveis obtidas em campo (p.e. IAF e biomassa) com a radiância registrada por um sensor remoto. Essa relação é, então, aplicada a todos os *pixels* de uma imagem para mapear a variável de interesse. Embora a abordagem empírica seja simples e rápida, ela apresenta uma série de limitações, dentre as quais se destacam: (i) o modelo de regressão não pode ser generalizado, ou seja, é válido apenas para as condições ambientais e de aquisição das imagens no momento em que os dados de campo foram adquiridos; (ii) as relações estatísticas são obtidas por laboriosos trabalhos de campo e (iii) efeitos de sombra e espalhamento múltiplo são negligenciados, o que produz estimativas incertas. Na segunda abordagem, chamada física/semiempírica, são utilizados MTRs para simular a reflectância de folhas e dosséis. Nos métodos semiempíricos, relações estatísticas entre IVs e dados simulados são utilizadas para estimar os parâmetros bioquímicos e biofísicos na imagem. Já na abordagem puramente física, essa estimativa é feita por inversão matemática do MTR. Nas seções seguintes será discutido sobre o processo de transferência radiativa, sua modelagem e inversão de modelos.

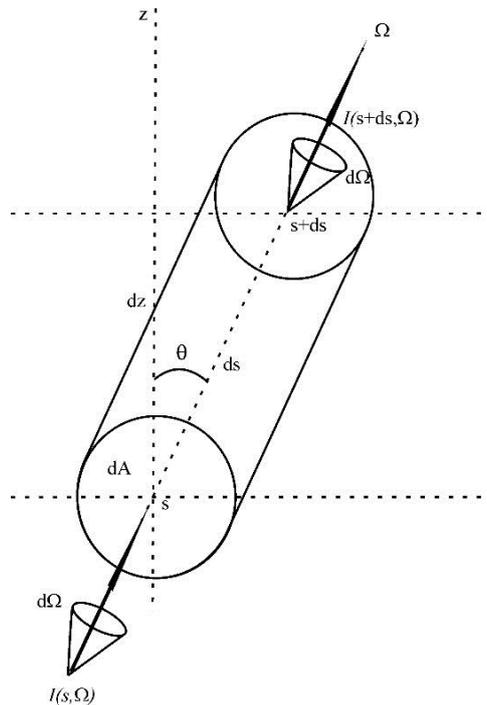
#### **2.3.1. Modelagem de transferência radiativa**

Como destacado anteriormente (Seção 2.1.2), dependendo da escala de observação o comportamento espectral da vegetação é afetado de formas distintas. Nesse contexto, por meio da modelagem do processo de transferência radiativa em folhas e dosséis é possível entender como a escala de observação impacta a aquisição dos dados e, conseqüentemente, a extração de informação. Isso é particularmente importante para o aperfeiçoamento das estimativas de parâmetros biofísicos e bioquímicos da vegetação por sensoriamento remoto.

### 2.3.1.1. Princípios físicos e bases conceituais

Os princípios físicos e bases conceituais do processo de transferência radiativa em tecidos vegetais estão calcados na teoria do transporte de fótons (ROSS, 1981). A modelagem desse processo trata a intensidade radiante de um estande vegetal de acordo com suas características óptico-geométricas, ângulos de iluminação e visada e intervalo espectral considerado. Para entender como a radiação se transfere em determinado meio deve-se remeter à equação de transferência radiativa, originalmente proposta por astrofísicos para estudar estrelas e superfícies planetárias. Essa equação propõe um tratamento heurístico para o espalhamento da radiação, em que os elementos espalhadores do meio (p.e. folhas) emitem e espalham a radiação de forma independente e incoerente (HAPKE, 2012). Para derivar a equação de transferência radiativa considere a Figura 2.2 abaixo:

Figura 2.2 – Representação esquemática do fluxo de radiação.



Fluxo de radiação  $I(s,\Omega)$  no ponto  $s$  se propagando na direção  $\Omega$ . Após sofrer processos de absorção e espalhamento o fluxo de radiação emerge do topo do cilindro na forma  $I(s + ds,\Omega)dAd\Omega$ .

Fonte: Adaptado de Hapke (2012).

Na Figura 2.2,  $I(s, \Omega)$  é o campo radiante que descreve a intensidade de radiação eletromagnética em um ponto  $s$  se propagando na direção  $\Omega$ .  $I(s+ds, \Omega)dAd\Omega$  é a intensidade de radiação que emerge do topo do cilindro com área  $dA$ , comprimento  $ds$  e volume  $dsdA$ . Analiticamente,  $I(s+ds, \Omega)dA$  é expresso como:

$$I(s+ds, \Omega)dAd\Omega = \left[ I(s, \Omega) + \frac{\partial I(s, \Omega)}{\partial s} ds \right] dAd\Omega \quad (2.3)$$

O termo  $\partial I(s, \Omega)/\partial s$  representa a mudança na intensidade de radiação devido a processos de espalhamento e absorção que ocorreram no interior do cilindro. Considerando apenas esses processos, a equação de transferência radiativa pode ser expressa como (REES, 2013):

$$\frac{dL_f(\theta, \phi)}{dz} = -(\gamma_a + \gamma_s)L_f(\theta, \phi) + \frac{\gamma_s}{4\pi} \int_{4\pi} L_f(\theta', \phi') p(\cos \Theta) d\Omega' \quad (2.4)$$

onde o termo  $L_f(\theta, \phi)$  é a radiância espectral que se propaga na direção  $(\theta, \phi)$ , a qual muda com a distância percorrida  $dz$ .  $\gamma_a$  e  $\gamma_s$  são os coeficientes de absorção e espalhamento, respectivamente. O segundo termo do lado direito da Equação 2.2 representa a radiação espalhada na direção  $(\theta, \phi)$  que provém da direção  $(\theta', \phi')$ .  $d\Omega' = \sin \theta' d\theta' d\phi'$  descreve o elemento de ângulo sólido integrado em todas as direções, ou seja,  $4\pi$  esteradianos. Finalmente,  $p(\cos \Theta)$  é a função de fase do espalhamento, em que  $\Theta$  é o ângulo de espalhamento dado por:

$$\cos \Theta = \cos \theta \cos \theta' + \sin \theta \sin \theta' \cos(\phi - \phi') \quad (2.5)$$

A Equação 2.4 que descreve o processo de transferência radiativa é do tipo integral-diferencial e em muitos casos não possui solução analítica. No entanto, sua aproximação pode ser feita via métodos numéricos como os de Monte Carlo (DISNEY et al., 2000), *Radiosity* (QIN; GERSTL, 2000), *Ray-tracing* (GASTELLU-ETCHEGORRY et al., 2004) e outros, como *doubling* e *multistream*, descritos em detalhe por Hapke (2012).

### 2.3.1.2. Modelos de Transferência Radiativa (MTRs)

Os primeiros modelos propostos foram baseados na teoria de reflectância difusa, ou teoria K-M, proposta por Kubelka e Munk (1931). Esses autores propõem uma solução para a equação de transferência radiativa (Equação 2.4), por meio de operações matemáticas mais simples, baseadas em duas equações diferenciais lineares que decompõem o fluxo de luz difusa nas direções ascendente ou *upward* ( $I \uparrow$ ) e descendente ou *downward* ( $I \downarrow$ ) segundos as Equações 2.6 e 2.7.

$$\frac{dI \uparrow}{dz} = -(\gamma_a - \gamma_s)I \uparrow + \gamma_s I \downarrow \quad (2.6)$$

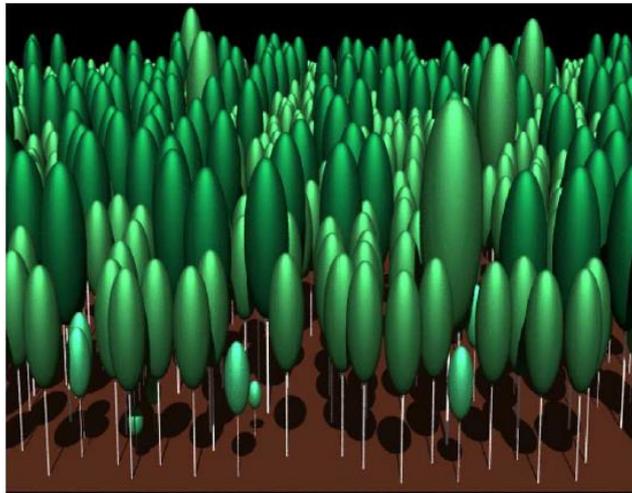
$$\frac{dI \downarrow}{dz} = -(\gamma_a - \gamma_s)I \downarrow + \gamma_s I \uparrow \quad (2.7)$$

O decaimento do fluxo de radiação é descrito pelos coeficientes  $\gamma_a$  e  $\gamma_s$  de absorção e espalhamento, respectivamente. A principal limitação dessa teoria é que a determinação dos parâmetros das equações diferenciais é realizada de forma empírica, o que pode levar a estimativas errôneas. Allen e Richardson (1968) adaptaram à teoria K-M um dossel vegetal com folhas distribuídas uniformemente e IAF constante. Dessa forma, a reflectância do dossel foi estimada pela soma dos fluxos de radiação difusa que emergiam na direção *upward*. Posteriormente, Allen et al. (1970) aperfeiçoaram a aplicação da teoria K-M, modelando o espalhamento múltiplo que ocorre no interior da folha pela construção de várias camadas distribuídas aleatoriamente e com espaços vazios preenchidos por ar.

Segundo Goel (1988), os modelos de transferência radiativa podem ser divididos em quatro tipos: geométricos, de meio túrbido, híbridos e de simulação computacional. Os modelos geométricos reproduzem a iluminação e sombreamento de um dossel por meio de formas geométricas definidas, orientadas de forma regular ou aleatória sob uma superfície de reflectância conhecida. Entre as formas utilizadas destacam-se: cones (LI; STRAHLER, 1985), esferas (JUPP et al., 1986) e elipsoides (CHARLES-EDWARDS; THORNLEY, 1973; GARCÍA-HARO; SOMMER, 2002). Um dos primeiros modelos geométricos foi proposto por Jahnke e Lawrence (1965) que representaram a vegetação em forma de discos e cones com variadas dimensões. Os autores, então, avaliaram o comportamento

da sombra desses objetos projetada em uma superfície com a variação do ângulo zenital de iluminação, concluindo que, para ângulos de iluminação menores ou iguais a  $20^\circ$  o efeito da forma dos objetos sobre a sombra projetada é mínimo. Os modelos geométricos são geralmente utilizados para representar dosséis esparsos em que a mudança dos ângulos de iluminação e visada afetam pouco o sombreamento mútuo dos elementos. A Figura 2.3 mostra um exemplo da utilização de um modelo geométrico para simular uma floresta boreal. As copas das árvores são representadas como elipsoides arranjados de forma aleatória visando simular as condições naturais.

Figura 2.3 – Representação de uma floresta boreal simulada.



Floresta boreal simulada no experimento *Radiation Transfer Model Intercomparison* (RAMI). O sol está posicionado atrás do observador.

Fonte: Widlowski et al. (2007).

A segunda categoria de MTRs é a de meio túrbido. Esses modelos são utilizados para representar dosséis vegetais homogêneos, assumindo que os mesmos são formados por camadas horizontais contínuas e uniformes. Segundo Goel (1988), os modelos de meio túrbido utilizam uma combinação da teoria de transmitância do dossel com a equação de transferência radiativa adaptada para dosséis homogêneos. O modelo mais popular desse tipo é o *Scattering by Arbitrarily Inclined Leaves* (SAIL) proposto por Verhoef (1984).

Os modelos híbridos surgem da combinação dos geométricos com os de meio túrbido. Sendo assim, a estrutura do dossel é modelada por formas geométricas e a transferência radiativa no interior do mesmo é aproximada por um meio túrbido.

Esse tipo de modelo deve ser utilizado quando o dossel estudado não é homogêneo, ou seja, não cobre uniformemente a superfície do solo. O Modelo de Transferência Radiativa para Dosséis Descontínuos Regulares (GRART) (CAMPOS, 2008) é um bom exemplo de modelo híbrido, pois integra as características estruturais do dossel (e.g. IAF e distribuição angular de folhas) com efeitos bidirecionais do interior das folhas. Outro exemplo é o PROSAIL, que integra o modelo de transferência radiativa dentro de folhas (PROSPECT) (JACQUEMOUD; BARET, 1990) com o SAIL (VERHOEF, 1984).

Os modelos de simulação computacional, por sua vez, incorporam novos elementos relacionados ao estande de plantas para modelar o processo de transferência radiativa. Nos modelos anteriormente discutidos, a representação da arquitetura do dossel é realizada utilizando-se formas geométricas, ou então, o dossel é considerado homogêneo. Tal condição gera simulações de reflectância que se afastam da realidade, principalmente em alvos heterogêneos e mais complexos. Com o surgimento das técnicas de Monte Carlo, ou seja, técnicas de geração de números aleatórios a partir de uma distribuição estatística, foi possível solucionar a equação de transferência radiativa (Equação 2.4) para uma situação multidimensional (espalhamento múltiplo de vários alvos). Disney et al. (2000) apresentaram uma revisão detalhada da aplicação de técnicas de Monte Carlo na modelagem de reflectância do dossel. As abordagens mais utilizadas que fazem uso dessa técnica são: *Radiosity* (QIN; GERSTL, 2000) e *Ray-Tracing* (KIMES; KIRCHNER, 1982; GASTELLU-ETCHEGORRY et al., 2004). Por meio de simulações de Monte Carlo, é possível construir um dossel hipotético em que seus elementos (i.e. folhas, ramos e galhos) estejam distribuídos de forma aleatória sobre uma superfície. Dessa forma, números aleatórios são gerados para descrever a trajetória da radiação incidente no topo do dossel até seu espalhamento, absorção, extinção ou retorno ao sensor (GOEL, 1988).

#### **2.3.1.2.1. PROSPECT**

O modelo PROSPECT foi proposto por Jacquemoud e Baret (1990) e se tornou o modelo mais utilizado para simular a reflectância e transmitância de folhas ao longo do domínio óptico (350-2500 nm) (JACQUEMOUD et al., 2009). Esse modelo sofreu aperfeiçoamentos ao longo dos anos e atualmente se encontra na

quinta versão (FÉRET et al., 2008). Por meio de uma série de parâmetros (Tabela 2.1), o PROSPECT-5 simula a reflectância e transmitância hemisférica direcional ao longo da faixa espectral de 400-2500 nm. Esses parâmetros possuem curvas específicas como mostra a Figura 2.4. O PROSPECT baseia-se na teoria *Plate-model* (ALLEN et al., 1969; JACQUEMOUD; BARET, 1990), em que a folha é representada como um empilhamento de  $N$  layers (camadas) que possuem uma textura heterogênea e dão origem a um processo de difusão isotrópica no interior das camadas. O PROSPECT tem sido amplamente utilizado para estudar as propriedades ópticas de folhas de espécies arbóreas florestais.

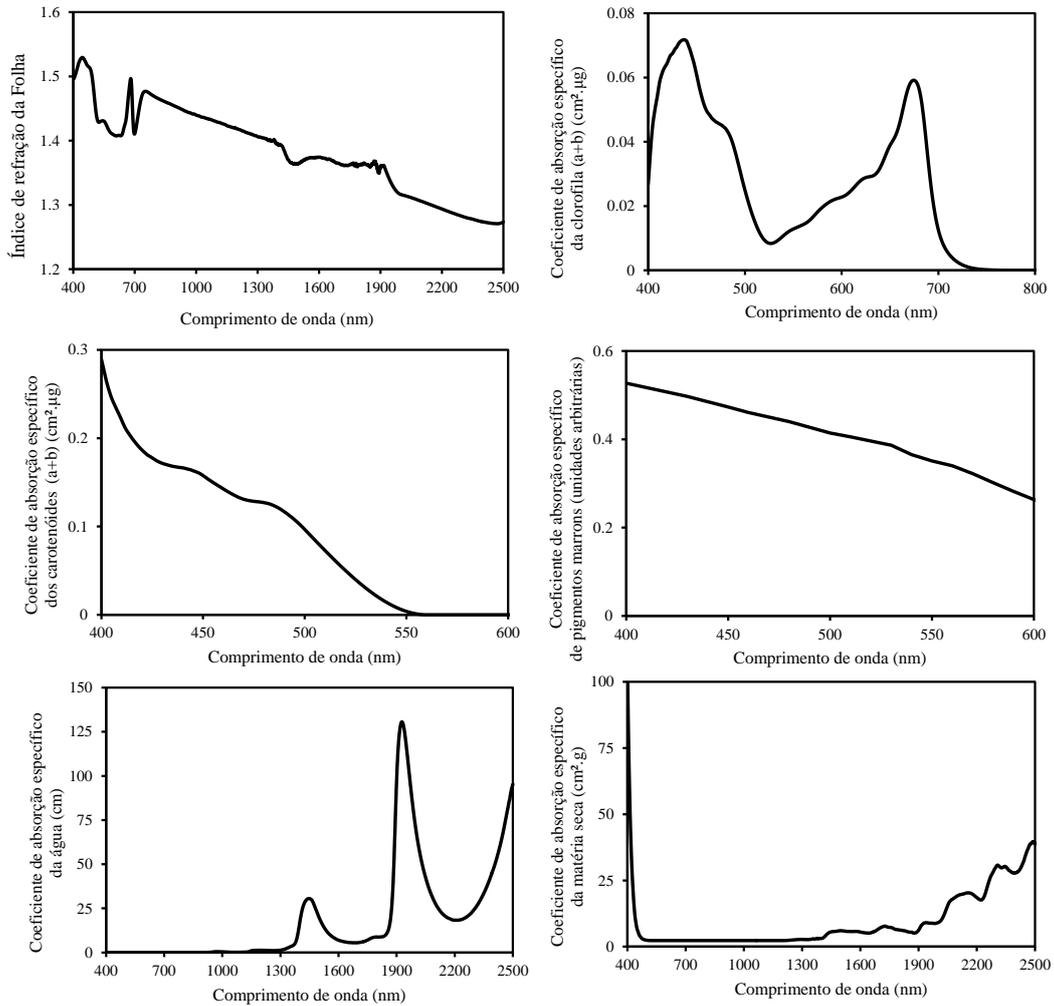
Tabela 2.1 – Parâmetros de entrada do modelo de transferência radiativa PROSPECT-5.

Abreviação	Parâmetro	Unidade
$C_{ab}$	Conteúdo de clorofila $a$ e $b$	$\mu\text{g.cm}^{-2}$
$C_{xc}$	Conteúdo de carotenoides	$\mu\text{g.cm}^{-2}$
$C_w$	Espessura equivalente de água	cm
$C_m$	Conteúdo de matéria seca	$\text{g.cm}^{-2}$
$N$	Parâmetro estrutural da folha	-

Fonte: adaptado de Féret et al. (2008)

Em florestas boreais, Malenovský et al. (2006) adaptaram o PROSPECT para melhor simular o comportamento espectral de acículas. As técnicas para medição da reflectância de acículas desenvolvidas nesse trabalho foram utilizadas por outros pesquisadores que estimaram a concentração de clorofila do dossel de florestas temperadas (ZARCO-TEJADA et al., 2004a; ZHANG et al., 2008; MALENOVSKÝ et al., 2013).

Figura 2.4 – Coeficientes utilizados no modelo de transferência radiativa dentro de folhas (PROSPECT-5).



Fonte: Adaptado do algoritmo proposto por Féret et al. (2008).

Ao nível foliar, Le Marie et al. (2004) utilizaram o modelo PROSPECT para simular mais de 11.000 espectros de folhas e avaliar diversos índices de vegetação desenvolvidos para estimar a concentração de clorofila (índices de clorofila). As simulações foram comparadas com dados de reflectância e clorofila obtidos em laboratório para 53 folhas de diferentes espécies. Ao relacionar valores de diversos índices com as correspondentes concentrações de clorofila, foi verificada uma discordância entre as bases de dados simulada e real. Isso indicou a falta de exatidão do PROSPECT em estimar a variável em questão, o que chamou a atenção da comunidade científica para a necessidade de uma nova calibração dos parâmetros do modelo. Nesse contexto, foram desenvolvidas as versões 4 e 5 do PROSPECT (Féret et al., 2008) em que novos coeficientes para clorofilas,

carotenoides, quantidade de água e matéria seca (Figura 2.4) foram incorporados. Barry et al. (2009) testaram a potencialidade do novo PROSPECT em estimar a concentração de clorofila de folhas de *Eucalyptus globulus*, obtendo um erro quadrático médio de  $4 \mu\text{g}\cdot\text{cm}^{-2}$ . Em florestas tropicais, o modelo PROSPECT-5 foi utilizado para avaliar a diversidade espectral de espécies arbóreas no Havaí (FÉRET; ASNER, 2011) e mais recentemente no Brasil (FERREIRA et al., 2013).

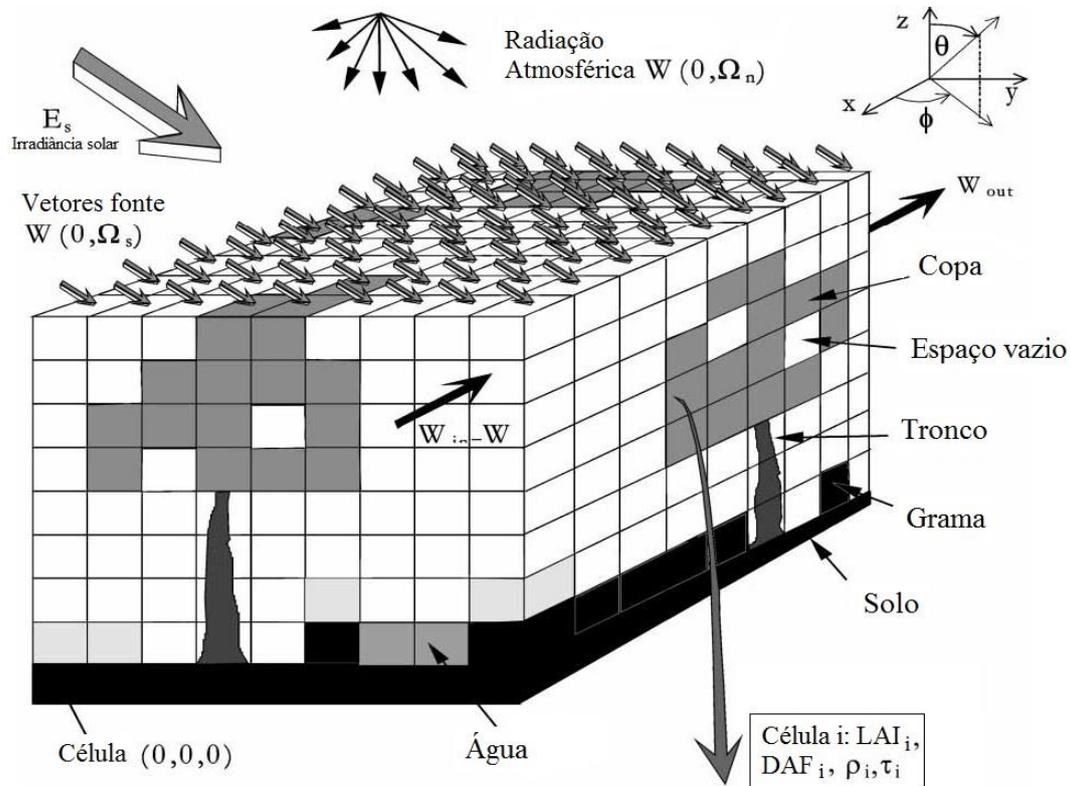
#### 2.3.1.2.2. DART

A maioria dos MTRs negligenciam diferenças estruturais dos dosséis vegetais na simulação da função de distribuição da reflectância bidirecional (FDRB) que rege seu comportamento espectral. Nesses modelos, os dosséis são tratados como um meio homogêneo, sendo que, na realidade, diferenças de altura das árvores, sobreposição de copas e sombreamento tornam esses alvos altamente anisotrópicos. A simulação da FDRB deve considerar, portanto, tais fatores para que seja realizada uma modelagem mais fiel do processo de interação da REM com os dosséis de plantas. Nesse contexto, surgem modelos que buscam considerar a arquitetura do estande vegetal e modelar o processo de transferência radiativa em três dimensões (3D) (refira-se a Widlowski et al. (2015) para uma revisão recente). O primeiro deles foi proposto por Kimes e Kirchner (1982), em que o processo de transferência radiativa é modelado em um sólido retangular subdividido em várias células, identificadas com coordenadas  $x$ ,  $y$  e  $z$  (Figura 2.5). Cada célula está associada a informações sobre seus componentes, por exemplo, vegetação, água, solo e área urbana que são utilizadas para modelar como a radiação incidente irá se comportar em seu interior. No caso de dosséis vegetais, cada célula conterá informações sobre as folhas, galhos, IAF, solos, etc. A radiação atmosférica é representada por vetores fonte  $W(0, \Omega_n)$  que, ao penetrarem em uma determinada célula, sofrem processos de absorção e espalhamento, de acordo com as informações contidas no interior da mesma. Seguindo essa abordagem, Gastellu-Etchegorry et al. (1996) desenvolveram o modelo *Discrete Anisotropic Radiative Transfer* (DART). O modelo DART sofreu algumas modificações e aperfeiçoamentos. Uma versão mais recente foi lançada por Gastellu-Etchegorry et al. (2015), na qual foi acoplado o modelo de transferência radiativa dentro de folhas PROSPECT (JACQUEMOUD; BARET, 1990). Dessa

forma, simulações ao nível foliar são realizadas pelo PROSPECT e então transportadas ao nível de dossel pelo DART.

O DART é um MTR 3D que simula a propagação da radiação em paisagens naturais e urbanas (GASTELLU-ETCHEGORRY et al., 2015). Ele permite a simulação do sinal adquirido por vários tipos de sensores passivos e ativos que operam no domínio óptico, incluindo instrumentos aerotransportados e orbitais como sensores hiperespectrais e *Light Detection and Ranging* (LiDAR). O DART representa a superfície da Terra em 3D. As cenas simuladas podem variar desde estruturas simples, como meios túrbidos, a objetos 3D altamente detalhados. Como destacado anteriormente, a cena 3D é dividida em células ou elementos de volume também conhecidos como *voxels*, que podem ser definidos pelo usuário de modo a aperfeiçoar o espalhamento da radiação e simular diferentes tipos de objetos.

Figura 2.5 – Modelo conceitual utilizado para simulação de processos de transferência radiativa pelo modelo Discrete Anisotropic Radiative Transfer (DART).



Fonte: Adaptado de Gastellu-Etchegorry et al. (2004).

Uma cena DART pode conter triângulos para posicionar elementos com precisão em seu interior (folhas, galhos, troncos), bem como meios túrbidos que representam estatisticamente a interação da luz com um dado volume (grupo de folhas, atmosfera ou água). Por exemplo, um meio túrbido que representa folhas no interior de uma copa é definido pela sua densidade de superfície foliar ( $m^2/m^3$ ), LAD e propriedades ópticas individuais das folhas (espectros de reflectância e transmitância). Cada *voxel* pode ser preenchido de forma independente com um meio túrbido e/ou triângulos (GASTELLU-ETCHEGORRY et al., 2015). Quando se utiliza uma geometria simplificada para representar árvores, a copa pode assumir uma forma elementar (cônica, esférica, elipsoidal) e é preenchida com um meio túrbido composto de folhas e elementos lenhosos; já o tronco é representado por facetos (triângulos). Além disso, uma fração de *voxels* vazios pode ser atribuída à copa, de modo a adicionar variabilidade e incluir um efeito parecido à aglutinação de folhas (SMOLANDER; STENBERG, 2003). Desse modo, os parâmetros que definem uma árvore são: estruturais (forma e tamanho da copa, distribuição das folhas e células vazias dentro da copa) e ópticos (propriedades ópticas de folhas e galhos).

Para a simulação de áreas florestais, árvores são geradas em posições aleatórias ou definidas pelo usuário através de coordenadas cartesianas, de modo que uma representação virtual da floresta pode ser obtida (Figura 2.6). Em ambientes tropicais, essa funcionalidade foi utilizada por Barbier et al. (2010) para verificar a relação entre atributos texturais do dossel e os diâmetros de copas e, assim, quantificar o impacto de parâmetros relacionados à aquisição de imagens de satélite (ângulos de iluminação e visada) nos resultados do método FOTO (COUTERON, 2002), utilizado para determinar o tamanho e heterogeneidade das copas.

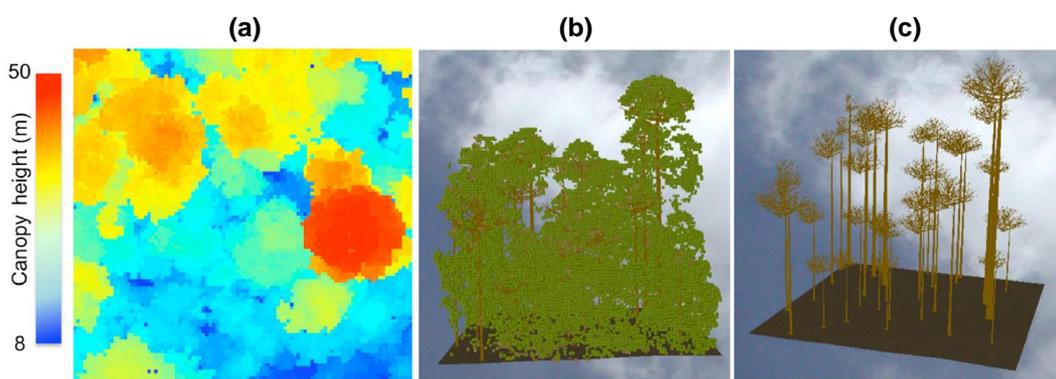
Figura 2.6 – Simulação de uma floresta tropical pelo modelo DART. A distribuição das árvores é aleatória, bem como seu formato e tamanho.



Fonte: DART (2014).

Mais recentemente, Morton et al. (2016) utilizaram o DART para construir uma representação 3D da floresta amazônica e estudar a variabilidade diurna e sazonal da utilização de luz. O modelo foi parametrizado com dados LiDAR de alta densidade e medições *in situ*. Uma representação realística da parcela permitiu que os autores pudessem investigar a influência da estrutura da floresta nas interações da radiação com o dossel.

Figura 2.7 – Simulação de uma parcela da floresta amazônica utilizando o modelo DART.



(a) Modelo de altura do dossel derivado de dados LiDAR; (b) vista oblíqua de *voxels* representativos de folhas e elementos lenhosos; (c) estrutura das árvores simuladas composta pelas copas, troncos e galhos.

Fonte: Morton et al. (2016).

### 2.3.2. Modelagem inversa

A inversão de MTRs é realizada para se estimar parâmetros bioquímicos e biofísicos da vegetação a partir de imagens de sensoriamento remoto. O processo de inversão consiste basicamente em encontrar o conjunto de parâmetros do modelo que produza o espectro de reflectância mais parecido com o espectro medido (p.e. a resposta espectral de um *pixel*). Esse procedimento depende primordialmente de uma boa concordância entre os dados reais e simulados. A seguir serão apresentadas as principais técnicas de inversão de MTRs, bem como alguns exemplos que as utilizaram para estimar parâmetros bioquímicos e biofísicos.

#### 2.3.2.1. Técnicas de inversão

##### 2.3.2.1.1. Otimização iterativa

Essas técnicas baseiam-se em procedimentos de otimização numérica que buscam encontrar o conjunto de parâmetros ( $\theta$ ) do MTR que minimizam a função de custo  $G(\theta)$  dada por:

$$G(\theta) = \sum_{\lambda_{\min}}^{\lambda_{\max}} \left[ (R_{mes}(\lambda) - R_{sim}(\lambda, \theta))^2 \right] \quad (2.8)$$

onde  $R_{mes}$  é a reflectância medida e  $R_{sim}$  é a reflectância simulada no comprimento de onda  $\lambda$ . O objetivo é encontrar a combinação de parâmetros do modelo que gere o espectro mais parecido possível com o espectro medido. O processo iterativo começa com uma suposição inicial de parâmetros e cessa apenas ao encontrar o mínimo de  $G(\theta)$ . Os algoritmos são baseados nos métodos quase-Newton utilizados para encontrar os pontos mínimo e máximo de funções. Um método do tipo Nelder-Mead Simplex (LAGARIAS et al., 1998) para inversão do modelo de transferência radiativa de folhas PROSPECT-5 (FÉRET et al., 2008) encontra-se disponível gratuitamente no endereço eletrônico: <http://teledetection.ipgp.jussieu.fr/prosail/> e pode ser utilizado em ambiente MATLAB®. É interessante ressaltar que, como a maioria dos métodos gradiente, na otimização iterativa o processo de iteração pode cessar ao encontrar um mínimo local, que nem sempre se refere à combinação de parâmetros que gera o

mínimo global. Além disso, essa técnica é considerada de alto custo computacional e impraticável para inversões em grandes escalas.

### **2.3.2.1.2. Abordagens *Look-Up Table***

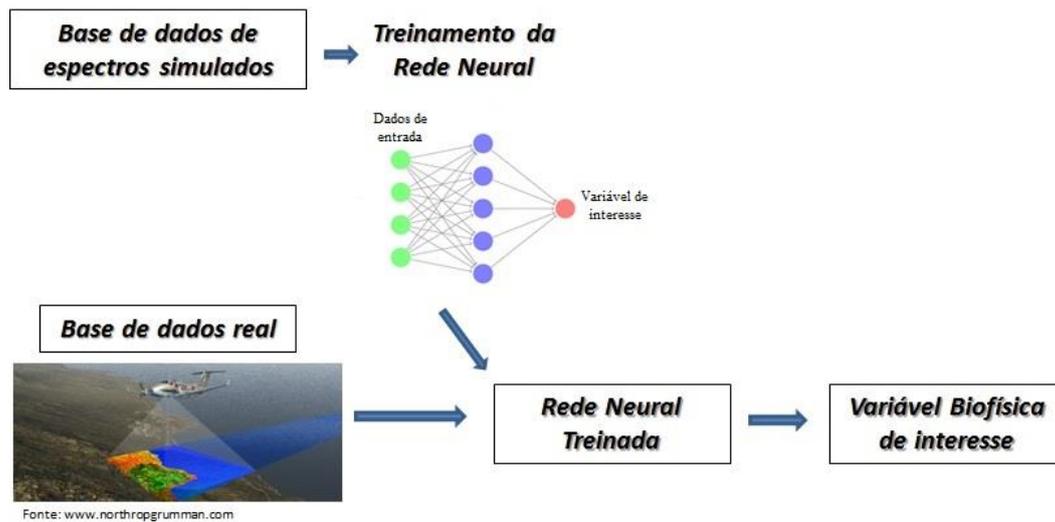
A abordagem *Look-Up Table* (LUT) é uma das técnicas mais simples, porém não menos efetiva, para inverter MTRs. A técnica consiste primeiramente na geração de uma base sintética de dados, conhecida como LUT, constituída de muitas simulações obtidas com diversas combinações de parâmetros do modelo. O segundo passo é encontrar o espectro simulado mais parecido com o medido, ou seja, aquele que minimiza a função de custo (Equação 2.8). Os parâmetros que geraram esse espectro serão, então, a solução do problema de inversão. Cabe aqui ressaltar, que a função de custo apresentada anteriormente (Equação 2.8) nem sempre é a mais adequada. Leonenko et al. (2013) sugerem outras métricas que podem aumentar a exatidão de estimativas de parâmetros biofísicos por inversão. A abordagem LUT não está sujeita às limitações de mínimos locais como as técnicas de otimização iterativa. No entanto, a referida abordagem é afetada por um problema conhecido como *ill-posed*, onde várias combinações de parâmetros do modelo podem gerar espectros muito semelhantes e não há garantia de que a combinação que atingiu o menor valor de  $G(\theta)$  seja a única. Sendo assim, Weiss et al. (2000) sugerem que seja obtida a média dos parâmetros que geraram as 50 melhores estimativas (menor valor de  $G(\theta)$ ). Além disso, a qualidade das estimativas pode ser melhorada introduzindo-se conhecimento *a priori* sobre o alvo a ser modelado (COMBAL et al., 2002).

### **2.3.2.1.3. Redes Neurais Artificiais**

Redes Neurais Artificiais (ANN, do inglês *Artificial Neural Network*) é uma poderosa técnica para extrair características da vegetação a partir de dados de sensoriamento remoto (KIMES et al., 1998). Assim como a abordagem LUT, ANN supera as limitações da técnica de otimização iterativa e vem sendo aplicada com sucesso na inversão de MTRs. O procedimento é composto basicamente por três etapas. Na primeira, deve-se utilizar o MTR, parametrizado com informações de campo, para gerar uma série de espectros simulados. Essas simulações servirão, na segunda etapa, como dados de entrada para o treinamento e validação

da ANN. Por fim, na terceira etapa, com a rede neural treinada, é possível utilizar a ANN treinada com dados de entrada reais (obtidos por sensores remotos) para extrair dos espectros o parâmetro bioquímico/biofísico de interesse (Figura 2.8) (p.e. MALENOVSKÝ et al., 2013).

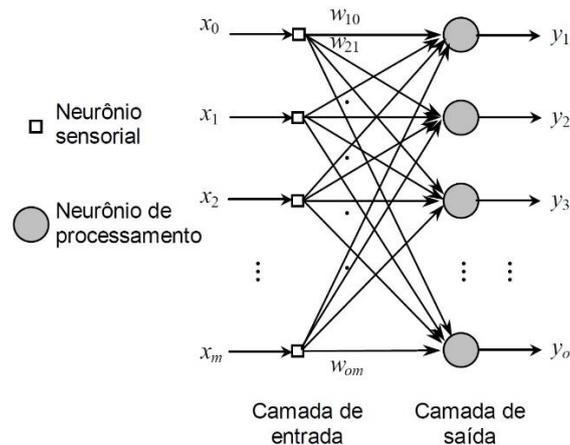
Figura 2.8 – Procedimento de inversão de modelos de transferência radiativa com Redes Neurais Artificiais (ANN).



Fonte: Produção do autor.

Para entender como essa técnica é utilizada na inversão de MTRs, é necessário conhecer a estrutura de funcionamento de uma rede neural que, na realidade, é uma forma de se construir uma relação matemática que transforma os valores de reflectância (simulados ou reais) das diversas bandas em variáveis bioquímicas/biofísicas do dossel vegetal. Para tanto, considere a Figura 2.9, que representa uma rede do tipo *feedforward*, em que o sinal se transporta apenas da entrada para a saída:

Figura 2.9 – Estrutura genérica de uma Rede Neural Artificial (ANN) com múltiplas camadas.



Fonte: Oliveira et al. (2010).

A camada de entrada é constituída pelos neurônios sensoriais  $x_1 \dots x_m$ , que são os valores de reflectância nas respectivas bandas. Esses valores são ponderados pelos pesos  $w$  e, então, transportados para os neurônios de processamento (círculos em cinza) da camada de saída. Os neurônios são núcleos que processam todos os sinais ponderados que recebem de acordo com a função  $f(I)$ :

$$f(I) = \left( \sum_{i=1}^n w_i x_i + b \right) \quad (2.9)$$

em que  $w_i x_i$  é o sinal  $x_i$  ponderado pelo peso  $w_i$ , e  $b$  é o viés (erro) associado ao neurônio. Os parâmetros  $w_i$  e  $b$  são livres e podem ser ajustados até que a rede transforme adequadamente os espectros de entrada em variáveis bioquímicas/biofísicas. Esse ajuste é realizado por uma etapa de treinamento realizada com dados simulados, em que se conhece os parâmetros do modelo. O processo de treinamento ajusta  $w_i$  e  $b$  iterativamente até a minimização da diferença quadrática média entre as variáveis de saída da rede neural e os parâmetros do modelo que deram origem aos dados de entrada (YEGNANARAYANA, 2009).

### 2.3.2.2. Exemplos de aplicação das técnicas de inversão

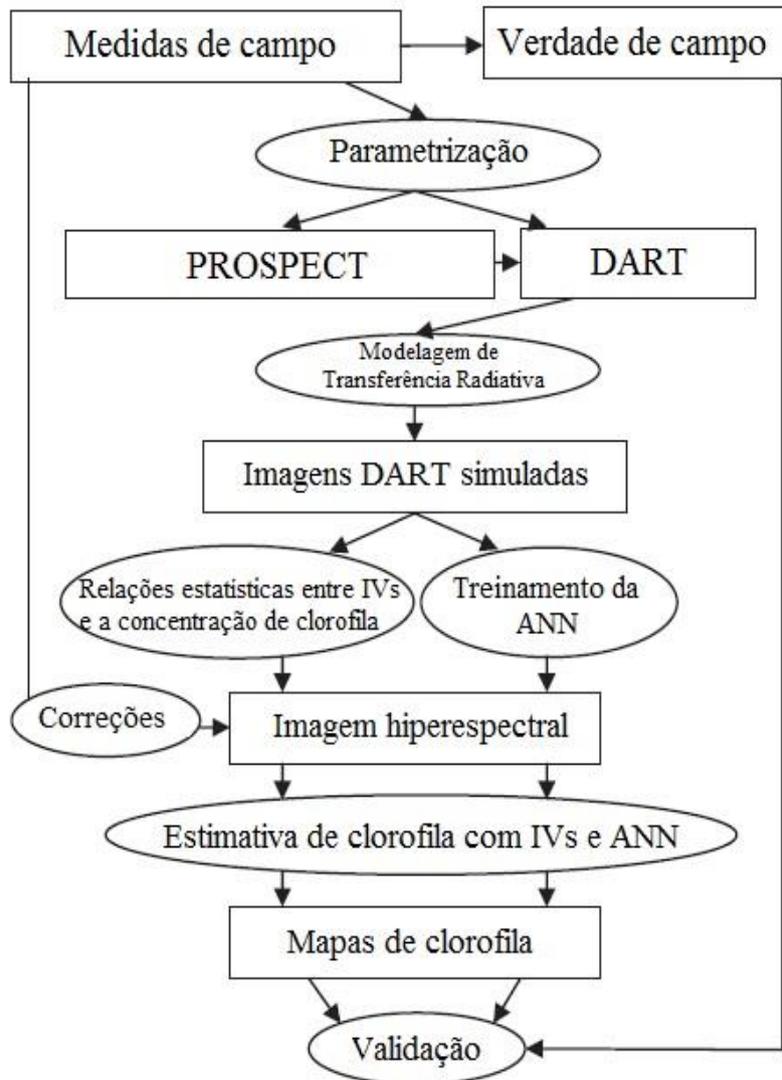
Pouco se sabe sobre o desempenho de MTRs na simulação da resposta espectral de florestas tropicais. No entanto, resultados promissores foram obtidos em

florestas temperadas com a utilização de MTRs 3D. Malenovský et al. (2013) utilizaram o modelo DART (GASTELLU-ETCHEGORRY et al., 2015) para simular a reflectância de árvores de *Pinus abies* e extrair a concentração de clorofila do dossel. Os autores apresentam em seu trabalho um fluxograma didático que ilustra como a inversão semiempírica do DART pode ser utilizada para extrair atributos da vegetação (Figura 2.10). O processo se inicia com a coleta de dados de campo que serão utilizados na validação das estimativas de clorofila e parametrização do modelo. O trabalho de campo é necessário para ajustar o intervalo de variação dos parâmetros do modelo e, assim, gerar simulações de reflectância que se assemelhem à realidade. No trabalho, os autores testaram a potencialidade de índices de vegetação (IVs) na estimativa do parâmetro de interesse. Dessa maneira, foram estabelecidas relações estatísticas (equações de regressão) entre as concentrações de clorofila simuladas e IVs. Em seguida, uma ANN foi treinada com os dados simulados. As equações de regressão, que apresentaram o menor erro quadrático médio, foram, então, utilizadas para estimar a clorofila nas imagens hiperespectrais obtidas concomitantemente aos trabalhos de campo. A título de comparação, a clorofila também foi estimada pela inversão do modelo DART com a rede neural treinada. O coeficiente de determinação entre as verdades de campo e as estimativas pela rede neural e pelo IV com melhor desempenho foi de 0,72, com erros quadráticos médios de  $2,27 \mu\text{g}\cdot\text{cm}^{-2}$  e  $2,18 \mu\text{g}\cdot\text{cm}^{-2}$ , respectivamente.

No âmbito de florestas tropicais, Asner e Vitousek (2005) inverteram um modelo de transporte de fótons em imagens hiperespectrais para estimar a concentração de nitrogênio e quantidade de água presentes no dossel de uma floresta no Havaí. O processo de inversão do MTR buscou, em síntese, encontrar a combinação de parâmetros do modelo que gerasse o espectro mais parecido com o espectro de um *pixel* da imagem. Os autores construíram uma LUT de espectros simulados que buscou representar a diversidade química e espectral da floresta estudada. Primeiramente, foi realizado um trabalho de campo para coletar a reflectância e transmitância das folhas de árvores e arbustos da área de estudo. Então, parâmetros bioquímicos e biofísicos foram estimados por inversão do PROSPECT (JACQUEMOUD et al., 2009). Dessa maneira, foi possível conhecer o intervalo

de variação de cada parâmetro e, assim, simular diversos espectros que, teoricamente, representariam a diversidade espectral da região estudada.

Figura 2.10 – Fluxograma para estimativa da concentração de clorofila utilizando modelagem de transferência radiativa e imagens hiperespectrais.



Fonte: Adaptado de Malenovský et al. (2013).

As simulações a nível foliar foram acopladas ao modelo de transporte de fótons e transferidas para o nível de dossel. Com isso, foi construída uma LUT que representa os *pixels* da imagem hiperespectral. A estimativa da concentração de nitrogênio e espessura equivalente de água para cada *pixel* foi realizada encontrando-se a combinação de parâmetros do modelo que gerou o espectro mais parecido com o espectro do *pixel* da imagem. A validação dos resultados com

dados de campo mostrou uma alta potencialidade do método na estimativa dos parâmetros bioquímicos (coeficiente de determinação de 0,92).

### **2.3.3. Modelagem direta**

A extração de atributos químicos da vegetação por abordagens físicas e semiempíricas normalmente são realizadas com modelos unidimensionais (1D) baseados em hipóteses calcadas na homogeneidade do estande vegetal (VERHOEF et al., 2007; JACQUEMOUD et al., 2009; HOUBORG et al., 2015). No caso de dosséis heterogêneos, caracterizados por uma estrutura complexa, que inclui efeitos de sombra e diversidade taxonômica, MTRs 3D são mais apropriados (SCHNEIDER et al., 2014, GASTELLU-ETCHEGORRY et al., 2015), devido à sua habilidade de lidar explicitamente com a estrutura do dossel. A investigação de potencialidades e limitações dos vários tipos de dados de sensoriamento remoto para extração de atributos químicos de ecossistemas florestais utilizando MTRs 3D requer a habilidade de produzir simulações realísticas e acuradas da resposta espectral. O realismo e acurácia de tais ferramentas de modelagem devem ser compatíveis com o nível de detalhes disponível para se realizar as simulações. Por isso, estudos de modelagem direta são importantes para se obter conhecimento acerca das limitações do modelo, do custo computacional requerido para a produção de simulações realísticas e mecanismos de transporte de fótons que contribuem para a variabilidade da reflectância do dossel. Além disso, a modelagem direta fornece a possibilidade de identificação de regiões espectrais que apresentam elevada concordância ou discrepância entre dados reais e simulados. Essa informação pode auxiliar a seleção de regiões espectrais adequadas para aplicação do modelo na estimativa de certo atributo do dossel e, também, o seu próprio aperfeiçoamento (SCHLERF; ATZBERGER, 2006).

Muitos fatores contribuem para o sinal registrado por sensores remotos, o que inclui as propriedades ópticas e estruturais da vegetação, a reflectância do solo e do substrato, as propriedades atmosféricas, o contexto topográfico e as condições geométricas de aquisição. MTRs 3D de última geração, como o DART, podem lidar detalhadamente com a descrição de todos esses elementos, tornando-o, por

um lado, uma ferramenta poderosa para analisar a contribuição desses fatores no sinal eletromagnético, mas por outro lado, essa descrição compreensiva requer uma elevada quantidade de informação para ajustar todos os parâmetros que controlam a difusão de radiação da cena, o que nem sempre está disponível. Por isso, a modelagem de dosséis heterogêneos complexos admite um certo número de suposições para descrever o nível ótimo de detalhamento de cada fator com base nas informações disponíveis e, principalmente, compreender os efeitos resultantes da escolha de valores padrão em variáveis que não possuem medidas experimentais. Até o momento, pouco se sabe sobre o desempenho de MTRs 3D para simular dados hiperespectrais aerotransportados adquiridos sobre florestas tropicais. Idealmente, a simulação de resposta espectral de árvores individuais deveria requerer uma parametrização detalhada da estrutura tridimensional do dossel, o que pode ser derivado de dados LiDAR (Figura 2.7) e intensivas medições de campo (MORTON et al., 2016; SCHNEIDER et al., 2014), combinada com medidas espectroscópicas das propriedades ópticas de cada elemento da cena (folhas, troncos, galhos, substrato). Em uma realidade prática, isso envolve um processo extremamente moroso e dispendioso.



### 3 MATERIAL

#### 3.1. Área de estudo

A área de estudo deste trabalho compreende a Reserva de Santa Genebra (RSG) (22°48' - 22°50' S, 47°06' - 47°07' W), localizada no município de Campinas/SP (Figura 3.1). A área possui 251,8 hectares (GUARATINI et al., 2008) e a formação florestal predominante é a floresta estacional semidecidual (VELOSO et al., 1991), submetida a uma estação seca com aproximadamente cinco meses de duração (Maio a Setembro) (LEITÃO FILHO, 1982). A elevação da área de estudo varia de 580 a 610 metros acima do nível médio dos mares. A RSG recebe aproximadamente 1503 mm de precipitação anualmente a temperatura média anual é de 20,5°C, variando entre 11 a 28.5°C. Levantamentos florísticos realizados na área registraram mais de 100 espécies arbóreas por hectare (FARAH et al., 2014; GUARANTINI et al., 2008). O dossel florestal é altamente heterogêneo e composto por espécies decíduas e perenes.

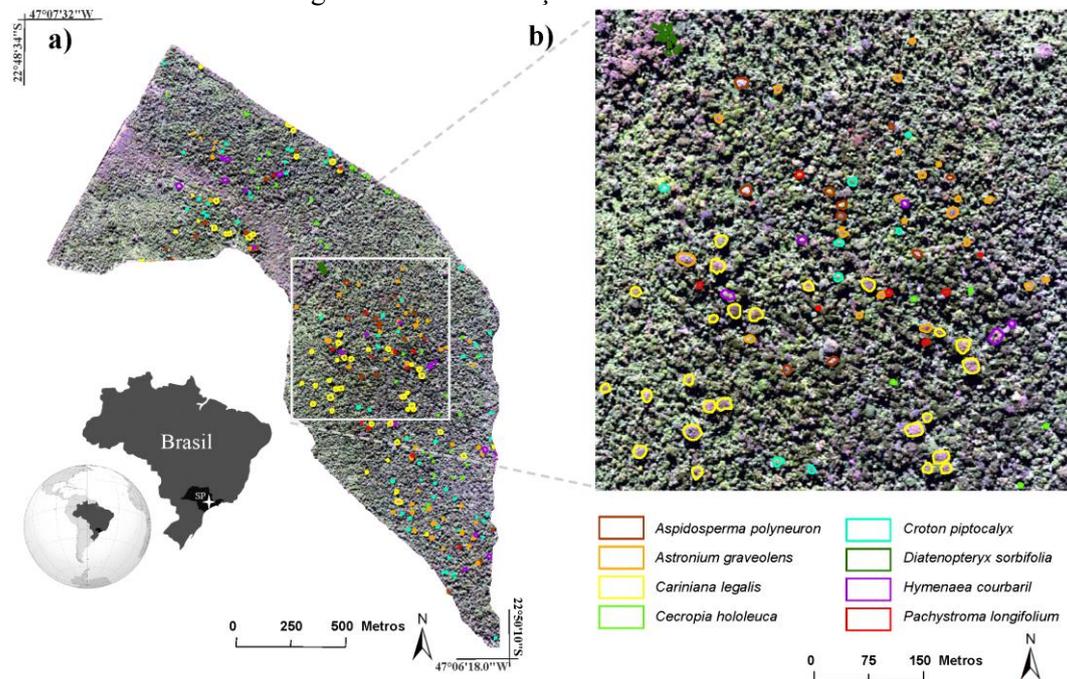
#### 3.2. Imagens hiperespectrais

Imagens hiperespectrais foram adquiridas com o sistema ProSpecTIR-VS (SpectTIR, Inc., EUA). Esse instrumento possui dois sensores que individualmente cobrem as regiões do visível/infravermelho próximo (VNIR, 450-970 nm) e do infravermelho de ondas curtas (SWIR, 970-2500 nm) do espectro eletromagnético, conhecidos como AisaEAGLE e AisaHAWK (Spectral Imaging, Inc. Oulu, Finlândia), respectivamente (Figura 3.2). A Tabela 3.1 sumariza as características dos sensores.

Imagens VNIR e SWIR foram adquiridas simultaneamente, totalizando 357 bandas espectrais (Tabela 3.1). Um Sistema de Navegação Inercial (INS, do inglês *Inertial Navigation System*) forneceu informações sobre a linha de visada do sistema de posicionamento global (GPS, do inglês *Global Positioning System*) para gerar um mapa de geometria interna (IGM, do inglês *Internal Geometry Map*) que contém informações sobre a localização geográfica de cada *pixel* bruto da imagem. O INS é equipado com uma unidade de mensuração inercial (IMU, do inglês *Inertial Measurement Unit*) acoplada a um GPS com 12 canais que utiliza

correções diferenciais em tempo integral capaz de fornecer um erro de posicionamento inferior a um metro para cada *pixel*.

Figura 3.1 – Localização da área de estudo.



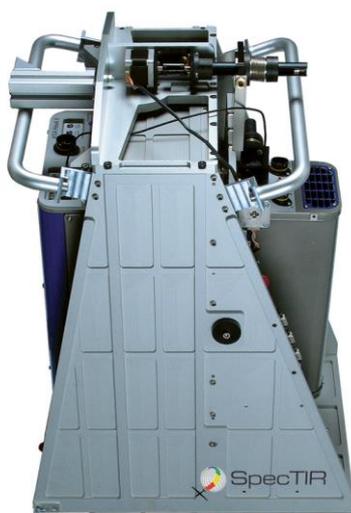
(a) Localização da área de estudo, com detalhe para a Reserva de St. Genebra em composição colorida de cor verdadeira (R = 639 nm, G = 548 nm, B = 460 nm) oriunda dos dados hiperespectrais. (b) Copas das árvores delineadas manualmente e identificadas ao nível de espécie em campo.

Fonte: Produção do autor.

Tabela 3.1 - Especificações do instrumento hiperespectral

ProSpecTIR-VS dual sensor		
Nome do sensor	AisaEAGLE	AisaHAWK
Detector	<i>Progressive scan</i> CCD	MCT with <i>maintenance-free cooler</i>
Intervalo espectral (nm)	400-970	970-2500
Resolução espectral (nm)	4	6
Nº de bandas espectrais	122	235
Resolução espacial (m)	1	1
Resolução radiométrica (bits)	12	14

Figura 3.2 – Sensor hiperespectral ProSpecTIR-VS.



Fonte: SpectTIR.

Os arquivos IGM de cada linha de voo foram utilizados para gerar uma *Geometric Lookup Table* (GLT) que contém as coordenadas de cada *pixel*. O sistema ProSpecTIR-VS foi montado em um avião que sobrevoou a área de estudo a uma altitude de 1.350 m acima do nível do solo. A aquisição das imagens foi realizada em condições de céu limpo no dia 7 de junho de 2010, iniciando-se às 13:27 horas e durou 28 minutos. Dez linhas de voo obtidas na direção norte-sul foram necessárias para cobrir toda extensão da reserva de St. Genebra. Os ângulos azimutal e zenital do sol no início da aquisição foram  $47,1^\circ$  e  $345^\circ$ , respectivamente.

### 3.3. Imagens WorldView-3 (WV-3)

O WV-3 é um satélite comercial de alta resolução espacial com capacidade de aquisição de dados no SWIR. Lançado no dia 13 de agosto de 2014, ele opera em uma órbita circular heliossíncrona a uma altitude de 617 Km. O WV-3 é equipado com um sistema pancromático (PAN) que possui 30 cm de resolução espacial, oito bandas VNIR (400-1040 nm) operando com 1.2 m, oito bandas SWIR com 3.7 m e 12 bandas CAVIS (*Clouds, Aerosol, Vapor, Ice, Snow*) de 30 m para estimativa de aerossóis e vapor de água. O instrumento possui um campo de visada (*swat*) de 13 Km, sendo capaz de adquirir imagens fora do nadir até um ângulo de  $20^\circ$ , o que fornece uma taxa de revisita de 4,5 dias. A imagem WV-3 utilizada neste trabalho foi adquirida no dia 24 de julho de 2015 a um ângulo de

9,8° em relação ao nadir e incluiu oito bandas VNIR e oito SWIR (Tabela 3.2). A imagem foi fornecida pela fundação *DigitalGlobe* radiometricamente corrigida e georreferenciada (produto conhecido com LV2A) para o *datum World Geodetic System* (WGS) 1984, projeção *Universal Transverse Mercator* (UTM), zona 23S. As correções radiométricas incluíram o preenchimento de detectores sem resposta, calibração da resposta relativa entre detectores e conversão radiométrica absoluta. As correções relativas ao sensor compreenderam a retificação da geometria interna dos detectores, correções de distorções ópticas, de varredura e de quaisquer variações entre as linhas de detectores (DigitalGlobe, 2016). As imagens SWIR foram coletadas com uma resolução espacial de 3,7 m, mas foram disponibilizadas com 7,5 m.

#### **3.4. Levantamento de copas de árvores individuais**

Inicialmente a copa de várias árvores foram delineadas manualmente por toda área de estudo, utilizando-se uma composição em cor verdadeira oriunda dos dados hiperespectrais na escala 1:1.300. Apenas as copas que eram claramente visualizadas nas imagens foram delineadas, buscando-se, assim, a resposta espectral mais pura possível das espécies. Em seguida, as árvores foram visitadas individualmente no campo, com o auxílio de um GPS de navegação com antena externa, e identificadas ao nível de espécie. A presença de lianas foi cuidadosamente verificada, evitando-se árvores dominadas por essas plantas. Estudos anteriores realizados em florestas tropicais mostraram a influência do recobrimento por lianas na reflectância e discriminação de espécies ao nível de dossel (KALACSKA et al., 2007). Ao todo, 354 árvores de 34 espécies foram identificadas. A Tabela 3.3 mostra o número de copas, *pixels*, o número médio de *pixels* por copa e do Diâmetro à Altura do Peito (DAP). Durante os trabalhos de campo, verificou-se uma acurácia posicional do GPS de aproximadamente 3 metros. As árvores puderam ser localizadas, pois a maioria possui uma copa de dimensões elevadas e, conseqüentemente, um expressivo DAP (Tabela 3.3). Espécies de modesto DAP como, por exemplo, *Cecropia hololeuca*, foram facilmente detectadas nas imagens devido às folhas de aspecto cinzento e brilhante.

Tabela 3.2 – Características da imagem do sensor orbital WorldView-3 (WV-3)

Banda espectral	Resolução espacial	Resolução radiométrica	Data de aquisição	Ângulo em relação ao nadir	Ângulos de elevação/azimutal solar
Azul (450-510 nm)	1,2 m	11 bits	24/07/2015	9.8°	327.4°/40.6°
Verde (510-580 nm)					
Amarelo (585-625 nm)					
Vermelho (630-690 nm)					
Borda do vermelho (705-745 nm)					
Infravermelho próximo 1 (NIR-1) (770-895 nm)					
Infravermelho próximo 2 (NIR-2) (860-1040 nm)					
Infravermelho de ondas curtas 1 (SWIR-1) (1195-1225 nm)	7,5 m	14 bits			
Infravermelho de ondas curtas 2 (SWIR-2) (1550-1590 nm)					
Infravermelho de ondas curtas 3 (SWIR-3) (1640-1680 nm)					
Infravermelho de ondas curtas 4 (SWIR-4) (1710-1750 nm)					
Infravermelho de ondas curtas 5 (SWIR-5) (2145-2185 nm)					
Infravermelho de ondas curtas 6 (SWIR-6) (2185 - 2225 nm)					
Infravermelho de ondas curtas 7 (SWIR-7) (2235-2285 nm)					
Infravermelho de ondas curtas 8 (SWIR-8) (2295-2365 nm)					

Para realização deste trabalho foram selecionadas apenas as espécies com mais de 10 indivíduos amostrados.

Tabela 3.3 – Lista das espécies, número de indivíduos, pixels, número médio de pixels por copa e mínimo e máximo Diâmetro à Altura do Peito (DAP). Em negrito, destaque para as espécies com mais de 10 indivíduos amostrados.

Espécie	Indivíduos	Código	Nº Pixels	$\bar{X}$ Pixels/Copas	DAP (cm)
<i>Aspidosperma parvifolium</i>	2		162	81	70-79
<b><i>Aspidosperma polyneuron</i></b>	23	AP	2587	112	48-96
<b><i>Astronium graveolens</i></b>	54	AG	5591	104	30-57
<i>Balfourodendron riedelianum</i>	4		277	69	42-67
<i>Cariniana estrellensis</i>	8		783	98	43-46
<b><i>Cariniana legalis</i></b>	50	CL	13396	268	52-111
<i>Cassia multijuga</i>	3		281	94	41-76
<b><i>Cecropia hololeuca</i></b>	39	CH	1610	41	19-28
<i>Centrolobium tomentosum</i>	2		92	46	35-43
<i>Chorisia speciosa</i>	2		83	42	27-35
<i>Copaifera langsdorfii</i>	4		501	125	33-45
<i>Cordia trichotoma</i>	1		39	39	34
<i>Croton floribundus</i>	3		193	64	30-42
<b><i>Croton piptocalyx</i></b>	58	CP	4639	80	35-71
<b><i>Diatenopteryx sorbifolia</i></b>	18	DS	380	21	49-63
<i>Endlicheria paniculata</i>	2		92	46	36-38
<i>Esenbeckia leiocarpa</i>	3		117	39	30-35
<i>Ficus guaratinica</i>	5		1733	347	> 120
<i>Galesia integrifolia</i>	4		597	149	65-73
<b><i>Hymenaea courbari</i></b>	18	HC	3784	210	65-95
<i>Inga luschnathiana</i>	8		859	107	18-44
<i>Jacaratia spinosa</i>	3		270	90	65-79
<i>Luetzelburgia guaissara</i>	2		78	39	23-42
<i>Machaerium brasiliense</i>	1		106	106	31
<i>Myroxylon peruiferum</i>	1		79	79	37
<i>Ocotea odorifera</i>	1		92	92	32
<i>Ocotea puberula</i>	1		98	98	27
<b><i>Pachystroma longifolium</i></b>	13	PL	773	59	50-70
<i>Piptadenia gonoacantha</i>	6		408	68	33-38
<i>Savia dictyocarpa</i>	6		211	35	47-54
<i>Schefflera morototoni</i>	3		143	48	41-56
<i>Schizolobium parahyba</i>	2		255	128	41-88
<i>Vernonia diffusa</i>	2		72	36	38-43
<i>Zeyhera tuberculosa</i>	2		114	57	38-46
<b>Total</b>	<b>354</b>		<b>40765</b>		

### 3.5. Dados espectrais ao nível foliar

Uma campanha de campo foi realizada na estação seca (primeira quinzena de junho de 2015), época semelhante àquela de aquisição das imagens hiperespectrais, para coleta das propriedades ópticas foliares das espécies arbóreas. Com o objetivo de gerar simulações da resposta espectral de árvores da área de estudo e compará-las com dados reais, após um levantamento prévio, decidiu-se coletar folhas apenas das espécies que possuíam mais do que 10 árvores amostradas (Tabela 3.3). Dessa forma, foi possível construir uma base de dados estatisticamente relevante. Devido a limitações de carácter técnico e financeiro, não foi possível realizar a coleta de folhas de todas as árvores visitadas em campo. Entretanto, buscou-se amostrar três ou mais indivíduos de cada espécie. A Tabela 3.4 mostra a quantidade de árvores e folhas amostradas. É interessante notar que, embora 39 árvores de *Cecropia hololeuca* tenham sido visitadas (Tabela 3.3), a resposta espectral das folhas dessa espécie não foi coletada. Devido à sua estrutura complexa e folhas com coloração acinzentada, optou-se por não realizar simulações da resposta espectral dessa espécie.

Tabela 3.4 – Lista das espécies, número de indivíduos e número de folhas amostrado para coleta de dados espectrais.

Espécie	Código	Indivíduos	Nº de folhas
<i>Aspidosperma polyneuron</i>	AP	5	59
<i>Astronium graveolens</i>	AG	8	103
<i>Cariniana legalis</i>	CL	3	36
<i>Croton piptocalyx</i>	CP	12	140
<i>Diatenopteryx sorbifolia</i>	DS	3	34
<i>Hymenaea courbaril</i>	HC	3	34
<i>Pachystroma longifolium</i>	PL	4	46
Total		38	452

#### 3.5.1. Coleta de folhas do topo do dossel e medição da reflectância

A coleta de folhas do topo do dossel foi realizada com um estilingue (Figura 3.3), uma vara de pesca com molinete contendo uma linha de *nylon* de 0,60 mm de diâmetro e uma corda de poliéster de 2 mm de diâmetro. O estilingue foi utilizado para lançar uma chumbada redonda de 180 g que estava amarrada à linha do molinete. Quando a linha atingia os galhos superiores da copa o molinete era travado e a linha era liberada aos poucos até que a chumbada atingisse o solo. Em

seguida, retirava-se a chumbada da linha e a ela era amarrada a corda de poliéster. O recolhimento da linha de nylon com o molinete fez com que a corda de poliéster subisse até o topo da copa e retornasse à vara de pesca. Finalmente, puxando-se as duas extremidades da corda o galho no qual ela estava entrelaçada era retirado. A coleta foi realizada de forma criteriosa, buscando-se selecionar apenas os galhos do topo do dossel que recebiam iluminação solar direta. Pequenas ramificações de galhos secundários, com aproximadamente 20 folhas, foram embaladas em uma sacola de polietileno contendo algodões umedecidos, e mantidas resfriadas em uma caixa térmica para evitar perda de umidade. Em no máximo cinco horas após a coleta, as folhas foram transportadas para o Laboratório de Espectroscopia de Reflectância (LER) do Departamento de Geociências (IG) da Universidade Estadual de Campinas (UNICAMP) para mensuração da reflectância bidirecional. As medidas foram realizadas com o espectrorradiômetro *FieldSpec-4* (Analytical Spectral Devices (ASD), Inc., Boulder, Colorado), utilizando o acessório *Plant Probe* combinado com o aparato *Leaf Clip*. O *FieldSpec-4* é composto por três espectrômetros. O primeiro cobre a faixa do VNIR (350-1000 nm) e possui resolução espectral de 3 nm. O segundo e terceiro possuem uma resolução espectral de 10 nm e cobrem a região do SWIR (1001-2500 nm). Após um processo de interpolação, os dados passam para a resolução espectral de 1 nm. O aparato *Leaf Clip* foi desenvolvido para ser utilizado com o acessório *Plant Probe*, que possui uma lâmpada halógena capaz de emitir radiação na faixa espectral de 350-2500 nm. Seu formato minimiza erros associados à luz difusa. O *Leaf Clip* possui uma extremidade rotativa que permite a medida de reflectância e transmitância bidirecionais (Figura 3.4) (ASD, 2011).

Figura 3.3 – Estilingue utilizado para a coleta de folhas do topo do dossel.



Fonte: Produção do autor.

Figura 3.4 – Acessório Plant Probe acoplado ao aparato Leaf Clip, utilizado para medir a reflectância bidirecional de folhas.



Fonte: Produção do autor

Adicionalmente, com o intuito de avaliar a capacidade do modelo DART em simular imagens hiperespectrais a partir de dados de campo, foi estabelecida uma parcela experimental circular com raio de 30 metros em uma região selecionada da área de estudo. A região foi escolhida de acordo com a presença de indivíduos arbóreos de grande porte e dossel fechado. O centro da parcela foi marcado com um cano de polietileno e sua posição geográfica foi obtida com o receptor GPS Geodésico Hiper+ (Topcon, Inc., Tóquio, Japão), de duas frequências (L1/L2), pelo método de levantamento relativo estático. Para tanto, foram utilizadas bases da Rede Brasileira de Monitoramento Contínuo (RBMC) dos Sistemas Globais de Navegação por Satélite (GNSS). As especificações da configuração do receptor GPS seguiram a abordagem de Santos (2013). Além disso, o Hiper+ foi acoplado a uma antena extensível de cinco metros para melhorar a captação do sinal (Figura 3.5). O centro da parcela foi observado por cerca de 30 minutos e, após o processamento, obteve-se um erro planimétrico de 0,295 metros.

Figura 3.5 – Receptor GPS Hiper+ acoplado a uma antena extensível de 5 metros para melhorar a captação do sinal.



A fotografia mostra a coleta do ponto central de uma parcela circular de 30 metros.

Fonte: Produção do autor.

Buscou-se estabelecer o centro de cada parcela próximo a um indivíduo arbóreo de porte mediano e capaz de escorar uma escada extensível de 8 metros. A escada foi utilizada para transpor os estratos inferiores e melhorar a visualização dos indivíduos que dominavam o dossel. Todos foram amostrados, independentemente de seu DAP. Para cada um desses indivíduos, foi registrada a distância ao centro da parcela, por meio do equipamento *laser TruPulse 200*, e o ângulo azimutal com uma bússola de navegação comum (Figura 3.6), possibilitando sua localização no interior da parcela. Concomitantemente à obtenção das informações posicionais, variáveis dendrométricas, como DAP, altura total, altura comercial e diâmetro da copa, foram mensuradas. Este último foi estimado a partir da banda pancromática de satélite WV-3 que possui resolução espacial de 0,3 m. Cada árvore foi registrada com um identificador e marcada com tinta chamativa para facilitar a sua identificação (Figura 3.7). Além disso, foram efetuadas coletas de folhas do topo do dossel com auxílio do estilingue (Figura 3.3), e também de folhas de bambú (*Merostachys riedeliana*) e serapilheira para medições espectrorradiométricas com o *FieldSpec-4*. A Tabela 3.5 sumariza os dados da parcela.

Figura 3.6 – Obtenção do ângulo azimutal ao centro da parcela por meio de uma bússola comum.



A medida foi realizada a aproximadamente 7 metros do solo para facilitar a visualização de indivíduos que dominavam o dossel.

Fonte: O autor.

Figura 3.7 – Exemplo de marcação de uma árvore que dominava o dossel no interior da parcela.



Espécie: *Croton piptocalyx*. Diâmetro à Altura do Peito: 22,5 cm. Altura total: 18 m.

Fonte: O autor.

Tabela 3.5 - Lista das espécies, altura total, altura comercial, diâmetro da copa, Diâmetro à Altura do Peito (DAP), distância ao centro e ângulo azimutal das árvores que dominavam o dossel da parcela circular com raio de 30 metros.

Espécie	Altura total (cm)	Altura comercial (m)	Diâmetro da copa (m)	DAP (cm)	Distância ao centro (m)	Ângulo azimutal (graus)
<i>Aspidosperma polyneuron</i>	25	14,2	14,7	73,3	21,9	205
<i>Astronium graveolens</i>	15	9,9	6,0	25,8	12,1	179
<i>Cariniana legalis</i>	31	15,3	27,7	181,4	26,2	263
<i>Cariniana legalis</i>	21	14,4	15,2	80,3	23,1	316
<i>Cecropia hololeuca</i>	10	8,9	5,2	21,6	21,8	155
<i>Cecropia hololeuca</i>	8	6,4	4,8	18,3	26,2	171
<i>Croton floribundus</i>	17	8,7	5,1	21,3	21,6	170
<i>Croton piptocalyx</i>	17	12,2	8,8	39,7	6,2	305
<i>Croton piptocalyx</i>	18	12,5	9,4	42,7	12,7	272
<i>Croton piptocalyx</i>	18	11,5	7,8	34,3	24,5	180
<i>Croton piptocalyx</i>	17,5	9,1	5,4	22,6	12,8	295
<i>Croton piptocalyx</i>	17	9,2	5,4	22,2	6,2	351
<i>Croton piptocalyx</i>	14	9,0	5,3	22,2	11,3	208
<i>Croton piptocalyx</i>	16	8,9	5,2	21,6	7,6	245
<i>Croton piptocalyx</i>	15	9,6	5,7	24,1	16,3	27
<i>Croton piptocalyx</i>	15	12,0	8,5	37,8	31,0	145
<i>Croton piptocalyx</i>	14,3	10,5	6,6	28,5	27,4	134
<i>Croton piptocalyx</i>	14	9,7	5,8	24,8	29,8	117
<i>Hymenaea courbaril</i>	20	11,8	11,9	30,2	29,5	146
<i>Inga luschnathiana</i>	18	12,1	8,7	38,3	3,5	99
<i>Inga luschnathiana</i>	15	11,1	7,2	31,3	12,7	132

Tabela 3.5 – Continuação

<i>Inga luschnathiana</i>	14,5	10,4	6,5	28,0	24,0	50
<i>Inga luschnathiana</i>	14,5	9,6	5,7	24,5	19,5	78
<i>Inga luschnathiana</i>	14	9,7	5,9	25,2	17,0	105
<i>Pachystroma longifolium</i>	13	10,8	6,9	30,2	20,9	356
<i>Piptadenia gonoacantha</i>	16	11,1	7,2	31,8	25,4	38
<i>Piptadenia gonoacantha</i>	16	9,4	5,6	23,7	13,9	52
<i>Piptadenia gonoacantha</i>	15	9,0	5,3	22,2	24,5	66
<i>Piptadenia gonoacantha</i>	15	12,5	9,5	42,9	17,8	39

## 4 MÉTODOS

### 4.1. Discriminação e mapeamento de espécies arbóreas

#### 4.1.1. Pré-processamento dos dados de sensoriamento remoto

##### 4.1.1.1. Imagens hiperespectrais

Primeiramente, as imagens hiperespectrais em radiância de cada linha de voo foram geometricamente retificadas com as suas respectivas GLTs e mosaicadas. Em seguida, a correção atmosférica (conversão para reflectância de superfície) foi realizada pelo algoritmo *Fast Line-of-Sight Atmospheric Analysis of Spectral Hypercubes* (FLAASH), uma abordagem baseada no modelo de transferência radiativa MODTRAN4, disponível no *software* ENVI (FELDE et al., 2009). Um modelo atmosférico tropical e um rural para aerossóis foram selecionados. O método *2-Band* (K-T) (KAUFMAN et al., 1997) foi utilizado para estimar a quantidade de aerossóis e uma visibilidade média da cena. A quantidade de vapor d'água para cada *pixel* foi determinada utilizando a feição de absorção centrada em 1135 nm. O método de suavização proposto por Boardman (1993) foi aplicado para reduzir artefatos espectrais oriundos do processo de correção atmosférica. Uma janela móvel sobre duas bandas adjacentes foi aplicada para promover uma suavização mínima e, ao mesmo tempo, remover imperfeições de bandas adjacentes (ITT Visual Information Solutions, 2009). Bandas ao redor de 1400 e 1900 nm foram excluídas devido ao forte efeito de absorção do vapor d'água atmosférico. Bandas nas proximidades de 970 nm também foram descartadas, pois estavam localizadas na zona de transição entre sensores e exibiram uma baixa relação sinal-ruído (SNR, do inglês *signal-to-noise ratio*). Canais ruidosos abaixo de 400 e acima de 2400 nm também foram descartados. Finalmente, 260 bandas estreitas, que cobriam o intervalo espectral de 450-2400 nm foram retidas para utilização posterior. As imagens resultantes foram mosaicadas em uma única cena, que praticamente não apresentou diferença em termos de brilho entre as linhas de voo (Figura 3.1).

#### 4.1.1.1. Índices de vegetação

Índices de vegetação (IVs) são operações aritméticas entre bandas e fornecem informações sobre as características biofísicas e bioquímicas das plantas. IVs de bandas estreitas exploram feições sutis de reflectância ou absorção que podem apenas ser visualizadas com dados hiperespectrais. Poucos estudos analisaram a habilidade de tais IVs na discriminação de espécies arbóreas tropicais. Neste trabalho, foram computados 19 IVs de bandas estreitas e um IV de banda larga (Tabela 4.1). De acordo com Roberts et al. (2011) esses 20 IVs podem ser classificados em três categorias de acordo com o parâmetro que realçam: estrutura, bioquímica e fisiologia vegetal.

Tabela 4.1 – Índices de vegetação utilizados no trabalho, juntamente com suas respectivas fórmulas e referências bibliográficas, classificados de acordo com Roberts et al. (2011).

Índice	Equação <sup>a</sup>	Referência bibliográfica
<b>Estrutura</b>		
<i>Normalized Difference Vegetation Index (NDVI)</i>	$(\rho_{865} - \rho_{672}) / (\rho_{865} + \rho_{672})$	Rouse et al. (1973)
<i>Enhanced Vegetation Index (EVI)</i>	$2,5 \times ((\rho_{865} - \rho_{672}) / (\rho_{865} + 6 \times \rho_{672} - 7,5 \times \rho_{465} + 1))$	Huete et al. (2002)
<i>Visible Green Index (VIg)</i>	$(\rho_{557} - \rho_{643}) / (\rho_{557} + \rho_{643})$	Gitelson et al. (2002a)
<i>Visible Atmospherically Resistant Index (VARI)</i>	$(\rho_{557} - \rho_{643}) / (\rho_{557} + \rho_{643} - \rho_{465})$	Gitelson et al. (2002a)
<b>Bioquímica</b>		
<b>Pigmentos</b>		
<i>Structurally Insensitive Pigment Index (SIPI)</i>	$(\rho_{802} - \rho_{465}) / (\rho_{802} + \rho_{681})$	Peñuelas et al. (1995)
<i>Pigment Sensitive Normalized Difference (PSND)</i>	$(\rho_{802} - \rho_{676}) / (\rho_{800} + \rho_{676})$	Blackburn (1998)
<i>Plant Senescence Reflectance Index (PSRI)</i>	$(\rho_{681} - \rho_{502}) / \rho_{753}$	Merzlyak et al. (1999)
<b>Clorofila</b>		
<i>Chlorophyll Absorption Reflectance Index (CARI)</i>	$[(\rho_{700} - \rho_{672}) - 0,2 * (\rho_{700} - \rho_{553})]$	Kim (1994)
<i>Modified CARI (MCARI)</i>	$[(\rho_{700} - \rho_{672}) - 0,2 * (\rho_{700} - \rho_{553})] * (\rho_{700} / \rho_{672})$	Daughtry et al. (2000)
<i>Red Edge Normalized Difference Vegetation Index (RENDVI)</i>	$(\rho_{753} - \rho_{700}) / (\rho_{753} + \rho_{700})$	Gitelson et al. (1996)

Antocianinas			
<i>Anthocyanin Index (ARI)</i>	<i>Reflectance</i>	$(1/\rho_{553})-(1/\rho_{700})$	Gitelson et al. (2001)

Tabela 4.1 - Continuação

<i>Simple Ratio (SR<sub>red/green</sub>)</i>	<i>Red/Green</i>	RED/GREEN <sup>b</sup>	Gamon et al. (1999)
Carotenoides			
<i>Carotenoid Reflectance Index 1 (CRI-1)</i>		$(1/\rho_{511})-(1/\rho_{553})$	Gitelson et al. (2002b)
<i>Carotenoid Reflectance Index 2 (CRI-2)</i>		$(1/\rho_{511})-(1/\rho_{700})$	Gitelson et al. (2002b)
Água			
<i>Normalized Difference Water Index (NDWI)</i>		$(\rho_{860} - \rho_{1247})/(\rho_{860} + \rho_{1247})$	Gao (1996)
<i>Normalized Difference Infrared Index (NDII)</i>		$(\rho_{821} - \rho_{1647})/(\rho_{821} + \rho_{1647})$	Hunt and Rock (1989)
Lignina			
<i>Normalized Difference Lignin Index (NDLI)</i>		$[\log(1/\rho_{1754}) - \log(1/\rho_{1680})]/[\log(1/\rho_{1754}) + \log(1/\rho_{1680})]$	Serrano et al. (2002)
Nitrogênio			
<i>Normalized Difference Nitrogen Index (NDNI)</i>		$[\log(1/\rho_{1510}) - \log(1/\rho_{1679})]/[\log(1/\rho_{1510}) + \log(1/\rho_{1679})]$	Serrano et al. (2002)
Fisiologia			
Eficiência do uso da luz			
<i>Photochemical Index (PRI)</i>	<i>Reflectance</i>	$(\rho_{534} - \rho_{572})/(\rho_{534} + \rho_{572})$	Gamon et al. (1997)
Estresse			
<i>Red Edge Position (REP)</i>		(máxima da primeira derivada: 680-750 nm)	Horler et al. (1983)

<sup>a</sup>  $\rho$  é a banda ProSpectTIR-VS mais próxima (os números representam o comprimento de onda em nanômetros) da formulação original do índice.

<sup>b</sup> RED e GREEN se referem à média de todas as bandas na região do vermelho (600-699 nm) e do verde (500-599 nm), respectivamente.

#### 4.1.1.1.2. Seleção de bandas

A classificação de dados hiperespectrais normalmente requer um procedimento prévio para reduzir o número de bandas e, assim, evitar o fenômeno de Hughes (HUGHES, 1968), ou seja, a piora no desempenho da classificação com o aumento da dimensionalidade. A seleção de um conjunto de bandas originais ou IVs com elevado poder discriminante é o procedimento mais comum. Os

algoritmos de seleção são divididos em métodos do tipo filtro ou *wrapper* (GUYON; ELISSEEFF, 2003). Neste trabalho foi adotado o método filtro. Na abordagem *wrapper*, a contribuição relativa de conjuntos de atributos é avaliada pela exatidão de um certo classificador, normalmente estimada por validação cruzada (KOHAVI; JOHN, 1997). Ao final do processo o conjunto de bandas que produziu a melhor exatidão de classificação é selecionado. Os *wrappers* são ajustados para um determinado classificador, proporcionando uma busca não genérica das variáveis. No procedimento por filtros, o mérito dos atributos é avaliado independentemente do classificador por um critério de separabilidade, usualmente uma distância estatística (GUYON; ELISSEEFF, 2003). Neste trabalho, foi utilizado o método de regressão *stepwise*, implementado na função “*stepwisefit*” do software MATLAB® (MathWorks, Natick, Massachusetts, EUA), para selecionar bandas dos intervalos VNIR e SWIR ou IVs para fins de classificação.

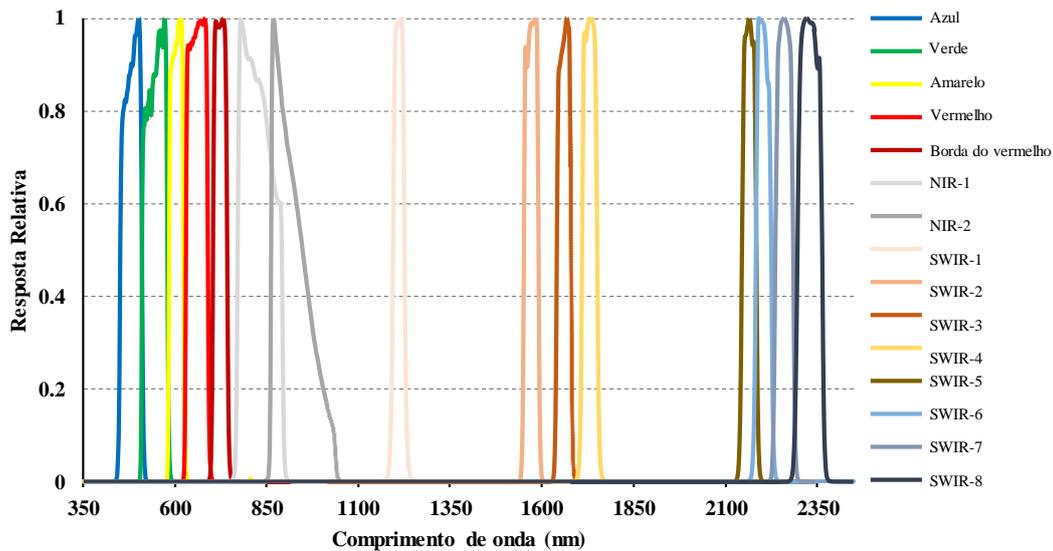
O método *stepwise* avalia sistematicamente a significância estatística de atributos, selecionando-os e removendo-os de um modelo de regressão múltipla (DRAPER; SMITH, 1998). A cada etapa, modelos com e sem uma potencial variável (banda) são testados por meio do cálculo do *valor-p* do teste *F*. Ao final do processo, um *valor-p* é calculado para cada banda. Até 30 bandas com *valores-p* estatisticamente significantes ( $\text{valor-p} < 0,01$ ) foram selecionadas para compor o conjunto final utilizado neste trabalho. A decisão de se utilizar 30 bandas foi baseada em estudos anteriores (FASSNACHT et al., 2014; FÉRET; ASNER, 2011; CLARK et al., 2005). O procedimento de seleção de bandas foi realizado tendo como dados de entrada os seguintes conjuntos: (I) 99 bandas VNIR; (II) 119 bandas VNIR e IVs; (III) 260 bandas VNIR e SWIR; (IV) 280 bandas VNIR, SWIR e IVs. A regressão *stepwise* forneceu bons resultados em experimentos preliminares.

#### **4.1.1.1.3. Simulação das bandas do satélite WorldView-3**

Dados hiperespectrais oferecem a oportunidade de simular bandas de sensores multiespectrais através de um processo de amostragem. Neste trabalho, foi empregada uma abordagem simples em que bandas estreitas foram agregadas para corresponder às bandas do satélite WorldView-3 (WV-3), utilizando as funções de

filtro do sensor (Figura 4.1). O WV-3 foi escolhido pois é a única plataforma orbital de alta resolução espacial ( $pixel < 5\text{ m}$ ) com capacidade de sensoriamento na região do SWIR. Buscou-se avaliar a utilidade das características espectrais das bandas WV-3 para a discriminação e mapeamento de espécies arbóreas da área de estudo.

Figura 4.1 – Funções de filtro das bandas do satélite WorldView-3.



Fonte: DigitalGlobe

#### 4.1.1.2. Imagens WorldView-3

As bandas VNIR e SWIR do satélite WV-3 foram convertidas para reflectância de superfície pelo algoritmo *DigitalGlobe Atmospheric Compensation* (DG-AComp). Para estimar a reflectância de superfície o algoritmo DG-AComp compensa a radiação no topo da atmosfera (TOA, do inglês *Top-Of-Atmosphere*) de efeitos de absorção atmosférica e de espalhamento utilizando o modelo de transferência radiativa MODTRAN (PACIFICI, 2013; PACIFICI et al., 2014). As imagens processadas pelo DG-Acomp foram obtidas diretamente com a DigitalGlobe. Para utilizar a elevada resolução espacial da imagem VNIR, foi realizada a fusão dos dados SWIR ( $pixel = 7,5\text{ m}$ ) com a banda NIR-2 ( $pixel = 1,2\text{ m}$ ) por meio da técnica Gram-Schmidt (LABEN; BROWER, 2000). O método Gram-Schmidt foi escolhido por ser capaz de preservar as características espectrais dos dados de baixa resolução espacial (EHLERS, 2008) e por ter sido utilizado com sucesso em

estudos anteriores que lidaram com o mapeamento de espécies arbóreas (CHO et al., 2015).

#### 4.1.2. Experimentos de classificação ao nível de *pixel*

##### 4.1.2.1. Seleção de amostras de treinamento e teste

Os *pixels* contidos no interior de cada ITC delineado manualmente (Seção 3.4) foram extraídos da imagem hiperespectral para construir uma base de dados com 280 atributos (VNIR, SWIR e IVs), 273 ITCs e 32.760 amostras. O mesmo procedimento foi realizado com a imagem WV-3, obtendo-se outra base de dados com 15 atributos (VNIR e SWIR) e 17.812 amostras, conforme mostra a Tabela 4.2. Tanto a base de dados oriunda das imagens hiperespectrais quanto a proveniente das imagens WV-3 foram aleatoriamente divididas em 60% para o treinamento e 40% para o teste dos métodos de classificação. Durante esse processo, a identidade do ITC foi respeitada, ou seja, *pixels* de treinamento e teste da mesma espécie advieram de ITCs diferentes. Estudos anteriores mostraram que a violação da identidade do ITC pode superestimar a exatidão de classificação (BALDECK; ASNER, 2014). O procedimento de separação das amostras citado anteriormente foi repetido 100 vezes, escolhendo-se aleatoriamente, a cada iteração, ITCs para treinamento e teste dos classificadores, bem como o armazenamento dos respectivos mapas de referência (ITCs de teste) para avaliação da exatidão. Mudanças sistemáticas na seleção de copas de treinamento e teste permitiram uma melhor avaliação da robustez dos modelos de classificação e sua habilidade de prever a classe de amostras desconhecidas.

Tabela 4.2 - Lista das espécies, número de indivíduos e pixel nas imagens hiperespectral e WorldView-3 (WV-3).

Espécie	Código	Indivíduos	<i>Pixel</i> hiperespectral	<i>Pixel</i> WV-3
<i>Aspidosperma polyneuron</i>	AP	23	2587	1371
<i>Astronium graveolens</i>	AG	54	5591	2981
<i>Cariniana legalis</i>	CL	50	13.396	8011
<i>Cecropia hololeuca</i>	CH	39	1610	665
<i>Croton piptocalyx</i>	CP	58	4639	2230
<i>Diatenopteryx sorbifolia</i>	DS	18	380	265
<i>Hymenaea courbaril</i>	HC	18	3784	2019
<i>Pachystroma longifolium</i>	PL	13	773	270
Total		273	32.760	17.812

#### 4.1.2.2. Métodos estatísticos de classificação

##### 4.1.2.2.1. Classificação de imagens hiperespectrais

Neste estudo, foi avaliado o desempenho de três métodos de classificação supervisionada: Análise Discriminante Linear (LDA), *Support Vector Machines* (SVM) com *kernel* Função de Base Radial e linear, e *Random Forest* (RF). Esses classificadores foram utilizados em investigações recentes para discriminar espécies arbóreas com dados hiperespectrais (CLARK; ROBERTS, 2012; DALPONTE et al., 2009; FÉRET; ASNER, 2013). A LDA tem sido amplamente usada em aplicações de dados de sensoriamento remoto, incluindo a classificação de espécies ao nível foliar e de dossel (CLARK et al., 2005; FÉRET; ASNER, 2013; FERREIRA et al., 2013). Essa técnica busca encontrar uma combinação linear de atributos capaz de separar uma ou mais classes (DUDA et al., 2001). Embora várias variantes da LDA existam (BANDOS et al., 2000), o presente trabalho se concentrou na versão clássica em que uma matriz de covariância comum é estimada para todas as classes sob o pressuposto de distribuição normal. O ajuste de parâmetros livres não é requerido.

SVM é um método não-paramétrico que classifica amostras de diferentes classes pela construção de hiperplanos em um espaço multidimensional (VAPNIK, 2000). Mais detalhes sobre o SVM e seu uso na classificação de imagens de sensoriamento remoto podem ser encontrados em Melgani e Bruzzone (2004) e Pal e Mather (2005). Este trabalho utilizou as duas variantes mais conhecidas: as formulações dos *kernels* linear (L-SVM) e Função de Base Radial (RBF-SVM, do inglês *Radial Basis Function*). SVM requer o ajuste de um ou mais parâmetros previamente à classificação, sendo a exatidão afetada pela escolha dos mesmos (CHAPELLE et al., 2002). L-SVM requer apenas o termo  $C$  referente ao erro, também conhecido como parâmetro de penalização, que controla a escolha e proporção de classes não-separáveis (CHERKASSKY; MULIER, 2007). Além de  $C$ , RBF-SVM necessita do ajuste do parâmetro  $\gamma_{\text{RBF}}$ . Diferentes combinações de  $C$  e  $\gamma_{\text{RBF}}$  foram testadas por meio da estratégia de busca em grade com validação. Primeiramente, uma grade foi construída com  $C$  variando de  $2^0$  a  $2^{20}$  e  $\gamma_{\text{RBF}}$  variando de  $2^{-5}$  a  $2^{10}$ , amostrados em etapas multiplicativas. A exatidão global de classificação para cada combinação de parâmetros foi estimada por um procedimento de validação cruzada por dez vezes com os dados de treinamento.

Devido ao elevado custo computacional 30% dos *pixels* do interior de cada ITC foram escolhidos ao acaso para realizar uma busca inicial dos parâmetros. Após a obtenção desse conjunto inicial, ou seja, aquele que produziu a melhor exatidão, a busca foi refinada em uma grade reduzida utilizada com uma base de dados construída após seleção aleatória de 50% dos *pixels* do interior de cada ITC. Por fim, o conjunto final de parâmetros foi escolhido para uso posterior. As classificações SVM foram realizadas com o pacote LIBSVM (CHANG; LIN, 2011), disponível para MATLAB®.

O algoritmo RF (BREIMAN et al., 2001) demonstrou bom desempenho para a discriminação de espécies arbóreas com dados de sensoriamento remoto (GHOSH et al., 2014). Esse classificador consiste em um conjunto de árvores de decisão em que uma amostra (*pixel*) é rotulada de acordo com o voto mais frequente entre as árvores. RF requer o ajuste de dois parâmetros conhecidos como número de árvores ( $n_{tree}$ ) e número de variáveis ( $m_{try}$ ), que é aleatoriamente selecionado durante o processo. Breiman e Cutler (2004) observaram que  $m_{try}$  afeta mais a exatidão de classificação do que  $n_{tree}$ . Em termos práticos,  $n_{tree}$  é normalmente ajustado em um valor de 500 ou superior (GHOSH et al., 2014) e  $m_{try}$  varia de acordo com o número de atributos (bandas). Nos experimentos reportados na Seção 4.1.2.1, o  $m_{try}$  ideal foi encontrado, variou de um até o número de bandas das bases de dados I, II, III e IV (Seção 4.1.1.1.2), sendo selecionado o valor que minimizava o erro *out-of-bag* no conjunto de treinamento. Todas as diferenças absolutas por pares entre as exatidões de classificação médias obtidas pelas bases de dados I, II, III e IV, com e sem a seleção de atributos, foram avaliadas pelo teste da soma de postos de Wilcoxon (HOLLANDER; WOLFE, 1999).

#### **4.1.2.2.2. Classificação de imagens WorldView-3**

A classificação das imagens WV-3 foi realizada apenas pelo algoritmo RF. Tanto o procedimento de seleção de amostras de treinamento e teste quanto o ajuste dos parâmetros do classificador foram realizados de forma idêntica às imagens hiperespectrais (Seção 4.1.2.2.1). Os experimentos de classificação foram realizados utilizando apenas as bandas VNIR e VNIR+SWIR.

#### 4.1.3. Variabilidade espectral

A variabilidade espectral intraespecífica de espécies arbóreas da FES é elevada devido a diferenças no padrão de queda de folhas entre árvores da mesma espécie (MORELLATO, 1991). A variabilidade espectral foi calculada pelo ângulo espectral  $\theta$  (Equação 2.2). O denominador da Equação 2.2 remove a dependência de amplitude oriunda de variações de brilho. Na realidade, diferenças de brilho não são adequadas para realçar diferenças espectrais entre indivíduos, particularmente em imagens de alta resolução com *pixel* menores do que ITCs (TOCHON et al., 2015). *Theta* ( $\theta$ ) foi calculado em dois níveis utilizando os dados hiperespectrais no intervalo VSWIR (450-2400 nm): (i) intraespecíes,  $\theta$  foi calculado para todas as combinações por pares da resposta espectral média de ITCs de uma mesma espécie; (ii) interespecíes,  $\theta$  foi calculado para todas as combinações por pares da resposta espectral média de ITCs de espécies diferentes. O teste da soma de postos de Wilcoxon foi usado para avaliar se a variabilidade intraespecífica apresentou diferença estatística em relação à interespecífica.

#### 4.1.4. Produção de mapas de espécies arbóreas

Além dos testes dos métodos de classificação ao nível de *pixel*, a habilidade dos classificadores em produzir mapas de espécies foi avaliada. O mesmo procedimento de separação de amostras de treinamento e teste apresentado na Seção 4.1.2.1 foi adotado. Os modelos de classificação obtidos pelo treinamento com todas as bandas VSWIR das imagens hiperespectrais (base de dados III, Seção 4.1.1.1.2), foram utilizados para rotular todos os *pixels* da imagem. Os mapas de espécies foram produzidos por uma abordagem de classificação orientada a objeto, que envolveu o delineamento automático de copas e a classificação de segmentos de acordo com uma regra de votação por maioria, ou seja, um dado segmento é rotulado de acordo com a classe majoritária dos *pixels* que o compõe.

Os *pixels* das imagens foram rotulados de acordo com sua probabilidade de pertencer a uma determinada classe. Dessa forma, a classe  $\omega_i$  será atribuída ao *pixel*  $x$ , se a seguinte condição for satisfeita:

$$x \in \omega_i \quad \text{se} \quad p(\omega_i | x) \geq \alpha \cdot \max(p(\omega_i)) \quad (4.1)$$

em que  $p(\omega_i/x)$  é a probabilidade de que  $\omega_i$  seja a classe correta para o *pixel*  $x$ , e  $\alpha$  é a porcentagem do valor máximo da probabilidade da classe  $\omega_i$ , isto é,  $p(\omega_i)$ . Neste trabalho,  $\alpha$  foi igual a 90%, de modo que apenas os *pixels* com alta probabilidade de pertencer a uma determinada classe fossem rotulados. Essa escolha foi motivada pelo fato de que mapear todas as espécies de uma área é impraticável e um elevado grau de incerteza seria obtido se todos os *pixels* de uma imagem fossem classificados (FÉRET; ASNER, 2013). A título de comparação, foram gerados mapas de espécies arbóreas da área de estudo com cada método. Esses mapas foram obtidos pelo treinamento dos classificadores com todos os 273 ITCs e todas as bandas VSWIR dos dados hiperespectrais e WV-3 simulados.

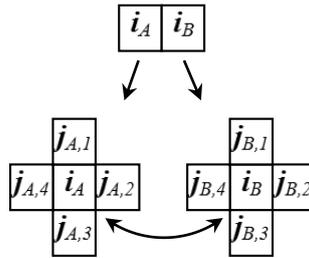
#### 4.1.4.1. Segmentação de imagens

O delineamento de copas em florestas tropicais é um desafio devido à estrutura complexa do dossel. As árvores possuem alturas heterogêneas e copas que frequentemente se sobrepõem, o que torna a definição de limites claros entre elas muito difícil, mesmo em imagens de alta resolução espacial. Além disso, os efeitos da FDRB levam à formação de *pixels* sombreados e iluminados no interior de uma mesma copa. A informação presente nas diversas bandas de imagens hiperespectrais pode ser utilizada para diminuir os efeitos de iluminação, ou mesmo, realçar feições espectrais que contribuam para melhorar o delineamento das copas.

O processo de segmentação empregado neste trabalho foi desenvolvido e ajustado especificamente para lidar com a questão do mapeamento de espécies arbóreas em florestas tropicais. Modificou-se uma versão do algoritmo de segmentação baseado na teoria de crescimento de regiões (SHAPIRO; STOCKMAN, 2001), semelhante ao implementado no *software* SPRING (CÂMARA et al., 1996) e disponibilizado em ambiente MATLAB® por Zanotta (2014). Inicialmente, o método escolhe de forma aleatória uma determinada quantidade de *pixels* na imagem. Em seguida, o crescimento de regiões ao redor desses *pixels* é realizado pela agregação de elementos que possuem propriedades similares (em termos de nível de cinza, por exemplo). Dessa forma, são formadas regiões ou segmentos. A

segmentação se inicia com uma agregação iterativa de *pixels* que apresentam similaridade mútua por vizinhança de primeira ordem (quatro elementos mais próximos). Considere  $i_A$  e  $i_B$  *pixels* vizinhos, como mostra a Figura 4.2. Ambos os *pixels* serão agrupados se, e somente se, o vizinho mais similar de  $i_A$  for  $i_{A,2}$  (i.e.  $i_B$ ) e o vizinho mais similar de  $i_B$  for  $i_{B,4}$  (i.e.  $i_A$ ).

Figura 4.2 – Similaridade mútua entre dois *pixels*



Fonte: Produção do autor.

Uma região será formada caso o referido teste seja verdadeiro e uma distância espectral ( $S$ ) entre os dois elementos seja menor do que um limiar de similaridade ( $T$ ), previamente estabelecido pelo usuário, conforme Equação 4.2:

$$S = \sqrt{(i_A - i_B)^2} \leq T \quad (4.2)$$

De forma parecida ao SPRING, o processo se inicia com um valor de similaridade menor do que aquele definido pelo usuário e aumenta a cada iteração de acordo com um grau de exigência ( $ex$ ) até que  $T$  seja atingido. Sendo assim, em um primeiro momento, apenas os *pixels* mais similares serão agrupados. Neste trabalho, um limiar provisório de similaridade ( $pT$ ) foi atualizado iterativamente pelo cálculo da razão  $T/ex$ . Na última iteração,  $ex$  é igual a 1.

Após unir dois *pixels*, uma nova região é formada, um identificador ( $id$ ) é atribuído e a média da região é atualizada em conformidade ao novo arranjo. Caso o *pixel*  $i$  tenha um outro vizinho que já pertença a uma região, identificada por  $id$ , sua similaridade será calculada com base na média dessa região. Sendo a diferença entre o *pixel*  $i$  a essa região adjacente menor do que a diferença desse *pixel* em relação aos seus vizinhos, ele será agrupado à região. O resultado desse processo frequentemente produz uma série de regiões contendo poucos *pixels* e,

por isso, é necessário agregá-las. Aqui, a regra para agregar as regiões foi baseada em sua separabilidade espectral, estimada pela distância de Jeffreys-Matusita (JM) (WACKER, 1971), uma métrica comumente utilizada em procedimentos de seleção de bandas. Considere  $R_A$  e  $R_B$  duas regiões vizinhas, com respectivos vetores de média  $M_A$  e  $M_B$  e matrizes de covariância  $C_A$  e  $C_B$ , a distância JM para duas classes com distribuição normal é dada por:

$$JM_{A,B} = \sqrt{2(1 - e^{-B})} \quad (4.3)$$

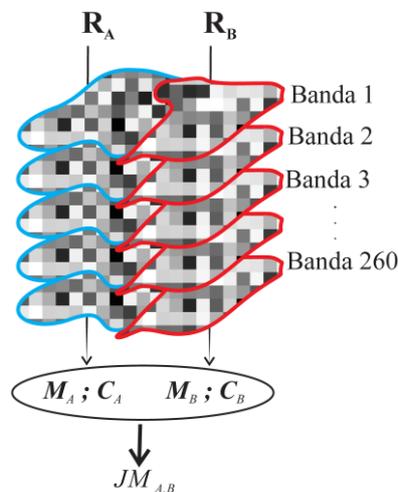
em que  $B$  é a distância de Bhattacharyya (KAILATH, 1967):

$$B = \frac{1}{8} (M_A - M_B)^T \left\{ \frac{C_A + C_B}{2} \right\}^{-1} \times (M_A - M_B) + \frac{1}{2} \ln \left\{ \frac{|(C_A + C_B)/2|}{|C_A|^{1/2} |C_B|^{1/2}} \right\} \quad (4.4)$$

onde  $T$  = função de transposição;  $\ln$  = logaritmo natural;  $||$  = determinante. A distância JM varia de 0 a 2, com valores altos indicando total separabilidade entre regiões adjacentes, a Figura 4.3 ilustra o processo. Finalmente, a região  $R_A$  será agrupada à região  $R_B$  se as seguintes condições forem satisfeitas:

- i)  $\|M_A - M_B\| < pT$ , com  $pT$  atualizado iterativamente até que  $T$  seja atingido;
- ii)  $JM_{A,B} \leq JM_{\text{limiar}}$

Figura 4.3 – Distância de Jeffreys-Matusita (JM) (Eq. 1) entre as regiões  $R_A$  e  $R_B$ , calculada com os vetores de média ( $M_A$ ;  $M_B$ ) e as matrizes de covariância ( $C_A$ ;  $C_B$ ).



Fonte: Produção do autor.

Após alguns testes preliminares, decidiu-se realizar o processo de delineamento de copas em duas etapas. Primeiramente, uma segmentação inicial foi realizada em uma composição colorida em falsa cor da imagem hiperespectral (R=639 nm, G=548 nm, B=460 nm; conforme mostrado na Figura 3.1). Essa etapa, pela aplicação de um limiar de similaridade baixo, produziu a super-segmentação da imagem para detectar objetos com padrão homogêneo de cor e textura. Em seguida, as regiões adjacentes foram unidas pela distância JM, conforme previamente detalhado, sendo o limiar igual a 0,01. A distância JM foi calculada com o conjunto total das bandas hiperespectrais.

#### **4.1.4.2. Avaliação da exatidão do mapeamento**

A avaliação de exatidão foi realizada para cada um dos 100 mapas produzidos pelos métodos de classificação, usando os *pixels* das regiões classificadas que coincidiram com os da referência (ITCs de teste). Os *pixels* não classificados, de acordo com a regra de decisão (Equação 4.1), não influenciaram as medidas de exatidão. A justificativa para utilização de apenas amostras coincidentes entre classificação e referência foi simular um procedimento de validação em campo, já que a visita a todos os segmentos classificados é operacionalmente inviável. Os resultados são apresentados em termos da média, após as 100 classificações, da exatidão de classificação de cada espécie, exatidão do produtor e do usuário, bem como a exatidão global. Adicionalmente, para cada método, foi calculado a porcentagem de ITCs do conjunto de validação que tiveram mais do que 80% dos *pixels* contidos em seu interior corretamente classificados.

#### **4.2. Simulação da resposta espectral de espécies arbóreas**

A modelagem de transferência radiativa em conjunto com o sensoriamento remoto hiperespectral tem sido utilizada para extração de atributos químicos da vegetação. Entretanto, essa abordagem é baseada em técnicas de inversão (Seção 2.3.2.1), que requerem primordialmente uma boa concordância entre os dados reais e simulados, mas pouco se sabe sobre o desempenho de MTRs na simulação da resposta espectral de espécies arbóreas tropicais.

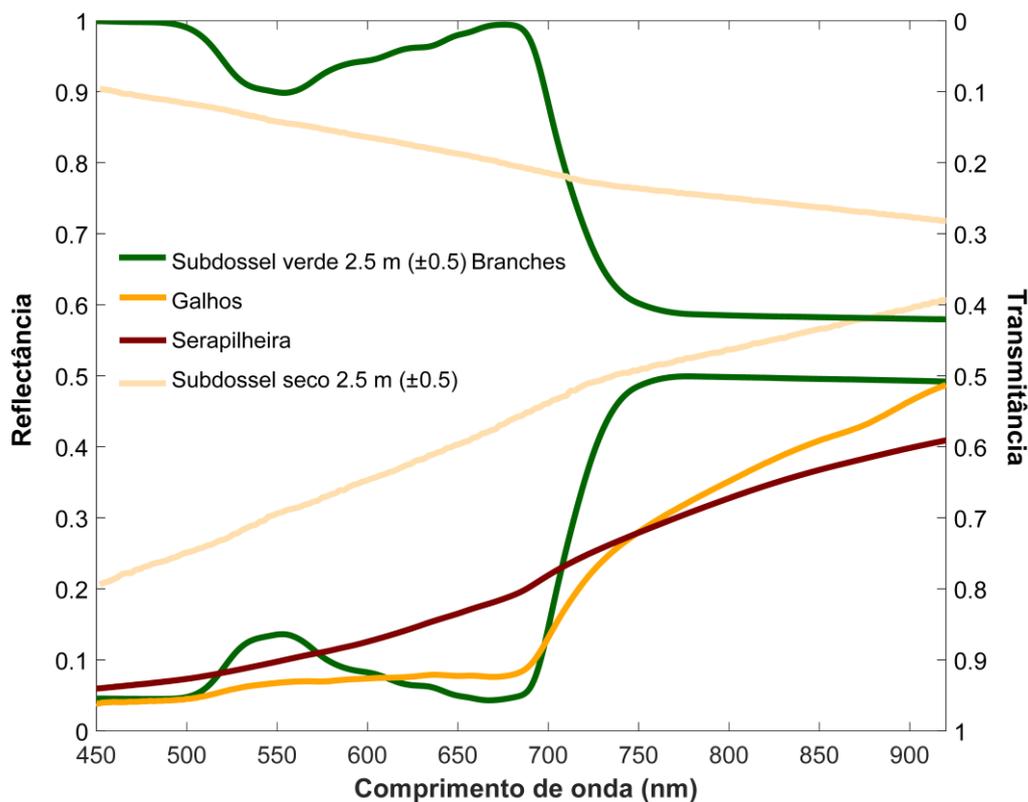
#### 4.2.1. Modelagem de transferência radiativa

Até o presente, a maioria dos estudos envolvendo modelagem de transferência radiativa 3D utilizou suposições sobre a estrutura do dossel e propriedades ópticas quando não há coleta extensiva de dados de campo ou aquisições LiDAR disponíveis. Essas suposições se baseiam em formas geométricas simplificadas como volumes elipsoidais para representar árvores, total ou parcialmente preenchidos com um meio turbido caracterizado por padrões homogêneos (densidade, distribuição angular e propriedades ópticas de folhas). Neste trabalho, objetivou-se testar a validade dessas suposições para simular de forma acurada a reflectância de ITCs da área de estudo. O principal interesse foi estudar a habilidade do modelo DART em simular sinais hiperespectrais ao se utilizar uma estrutura simplificada das árvores, quando suas propriedades ópticas são conhecidas. A base de dados de copas individuais, que pode ser obtida pelo delineamento de árvores na imagem hiperespectral (Seção 3.4) e coleta de propriedades ópticas foliares (Seção 3.5), foi utilizada como base de dados experimental.

Uma estratégia de simulação foi desenvolvida baseada na representação simplificada de árvores para simular a resposta espectral dos ITCs ao nível de dossel. Cada árvore foi representada como um indivíduo isolado localizado no centro de uma cena de 10x10 m. A copa foi assumida com forma arredondada, com diâmetro de 10 m, centrada a uma altura de 20 m do chão, contendo *voxels* de 0,5 m<sup>3</sup> preenchidos com folhagem e galhos lenhosos, modelados por dois tipos de meio turbido, cada um com sua densidade e propriedades ópticas definidas. A proporção de *voxels* vazios no interior da copa foi estudada como um parâmetro a parte, influenciando a reflectância da árvore. A reflectância espectral dos galhos foi ajustada de acordo com o espectro da casca obtido em campo. Cada combinação de galhos, folhas, densidade do subdossel e proporção de *voxels* vazios resulta em um determinado Índice de Área da Planta (PAI, do inglês *Plant Area Index*: IAF + área dos elementos lenhosos). O subdossel foi representado como um meio turbido de 2,5 m ( $\pm 0,5$  m) de altura que cobria um terreno plano. Um espectro padrão do DART foi utilizado para caracterizar as propriedades ópticas do subdossel, galhos e serapilheira (Figura 4.4). As propriedades ópticas das folhas das espécies arbóreas foram simuladas com o modelo PROSPECT-5

(FÉRET et al., 2008). Como apresentado na Seção 2.3.1.2.1 (Tabela 2.1), o PROSPECT-5 simula a reflectância e transmitância direcional-hemisférica da folha ao longo do intervalo espectral de 400-2500 nm utilizando os seguintes parâmetros: Clorofila  $a+b$  ( $C_{ab}$ ,  $\mu\text{g}/\text{cm}^2$ ), Carotenoides ( $C_{xc}$ ,  $\mu\text{g}/\text{cm}^2$ ), Espessura equivalente de água ( $C_w$ ,  $\text{g}/\text{cm}^2$ ), conteúdo de matéria seca ( $C_m$ ,  $\text{g}/\text{cm}^2$ ) e o parâmetro estrutural da folha ( $N$ ).

Figura 4.4 – Propriedades ópticas do subdossel verde e seco com 2,5 m ( $\pm 0,5$  m) de altura, galhos e serapilheira utilizados nas simulações do modelo DART.



Fonte: Produção do autor.

O fator de reflectância bidirecional foi modelado por uma abordagem *Ray-Tracing* (KIMES; KIRCHNER, 1982, GASTELLU-ETCHEGORRY et al., 2015), onde o sol e a atmosfera eram as únicas fontes de radiação. A reflectância no topo de dossel foi obtida iterativamente seguindo fluxos de radiação ao longo de 100 direções discretas (YIN et al., 2013). As especificações do instrumento ProSpecTIR-VS referente ao sensor AisaEAGLE (Tabela 3.1), sejam elas: resposta espectral de filtro de cada banda, campo de visada (FOV, do inglês *Field of View*), direção de visada, altitude e posição do sol, foram configuradas

para simular o momento de aquisição da imagem. As simulações foram realizadas para as 99 bandas do sensor AisaEAGLE, que adquire dados no VNIR, pois os dados do SWIR foram obtidos por outro sensor e, portanto, com configurações distintas. A versão 5.6.1 do DART com a funcionalidade *multi-threading* foi utilizada em ambiente UNIX e um computador com elevada capacidade de processamento e memória (processador com 6 núcleos e 64 GB RAM).

#### 4.2.2. Geração da *Look-Up-Table*

Uma LUT foi gerada pela variação de 11 parâmetros do DART, que podem ser divididos em três categorias: propriedades estruturais do dossel; propriedades biofísicas (correspondente aos parâmetros de entrada do modelo PROSPECT-5) e propriedades ópticas da cena. As propriedades estruturais do dossel são:

- Distribuição angular de folhas (LAD): seis funções foram consideradas para caracterizar a LAD, de acordo com Wit (1965): planófila (folhas horizontais são mais frequentes), erectófila (folhas verticais são mais frequentes), plagiófila (folhas oblíquas são mais frequentes), extremófila (folhas oblíquas são menos frequentes), esférica (a frequência relativa do ângulo foliar é a mesma dos elementos de uma esfera), uniforme (a proporção dos ângulos foliares é a mesma em qualquer ângulo). Essas categorias dependem do ângulo de inclinação das folhas que variaram de acordo com a LAD: 26,76° para planófila, 63,24° para erectófila e 45° graus para plagiófila, extremófila e uniforme, e 57.3° para esférica.
- Densidade de galhos por *voxel* (DBF, do inglês *Density of branches per voxel*): densidade de volume ( $m^2/m^3$ ) de superfícies planas infinitamente pequenas com propriedades ópticas de galhos;
- Densidade de folhas por *voxel* (DLF, do inglês *Density of leaves per voxel*): densidade de volume ( $m^2/m^3$ ) de superfícies planas infinitamente pequenas com propriedades ópticas de folhas;
- Proporção de células preenchidas no interior da copa (pCells): porcentagem de células preenchidas com folhas distribuídas aleatoriamente no interior da copa. A proporção de células preenchidas com galhos foi fixada em 50% para todas as simulações;

- Fator de reflectância dos galhos (OBF, do inglês *Optical Branch Factor*): *offset* aditivo aplicado aos espectros de galhos;
- Fator de reflectância do solo (OGF, do inglês *Optical Ground Factor*): *offset* aditivo aplicado ao espectro do solo;

Os parâmetros biofísicos das folhas como descritos pelo modelo PROSPECT-5 (Seção 2.3.1.2.1) são:

- $C_{ab}$ ,  $C_{xc}$ ,  $C_m$ ,  $C_w$  e  $N$

Para cada uma das sete espécies arbóreas incluídas nesta etapa do estudo (Tabela 3.4) foram obtidos parâmetros bioquímicos e estruturais a partir da reflectância das folhas pela inversão do PROSPECT-5. A inversão foi realizada por uma abordagem de otimização iterativa, por meio da minimização da função de mérito apresentada na Equação 2.8. O método de reflexão-interior de Newton (COLEMAN, 1996) com restrições de limites foi aplicado para minimizar  $G(\theta)$ . O modelo PROSPECT-5 foi utilizado com sucesso em investigações anteriores para estimar parâmetros bioquímicos de folhas (BARRY et al., 2009; FÉRET et al., 2008) e simular a resposta espectral de espécies arbóreas tropicais ao nível foliar (FÉRET; ASNER, 2011; FERREIRA et al., 2013). A distribuição estatística (média e desvio padrão) dos dados de química foliar e propriedades estruturais derivada da inversão do PROSPECT-5 foi então utilizada para a geração de uma base de dados simulada das propriedades ópticas (reflectância e transmitância) de cada espécie. A Tabela 4.3 sumariza os parâmetros do DART e PROSPECT-5, bem como seus intervalos de variação para geração da LUT.

Tabela 4.3 – Parâmetros DART + PROSPECT-5, suas faixas e incrementos de variação e natureza, utilizados para a construção da Look-Up-Table (LUT)

Parâmetros estruturais do dossel	Unidade/Tipo	Min.	Max.	Incremento	Incremento OAT-SA <sup>a</sup>	Caso-base	Natureza
Distribuição angular de folhas (LAD)	<i>planófila</i>	-	-	-	-		
	<i>erectófila</i>	-	-	-	-		
	<i>plagiófila</i>	-	-	-	-	<i>planófila</i>	Categórica
	<i>extremófila</i>	-	-	-	-		
	<i>esférica</i>	-	-	-	-		
	<i>uniforma</i>	-	-	-	-		
Densidade de galhos por <i>voxel</i> (DBF)	volume %	0	0,75	0,25	0,25	10	Categórica
Densidade de folhas por <i>voxel</i> (DLF)	m <sup>2</sup> /m <sup>3</sup>	0,5	3	0,5	0,5	1	Contínua
Proporção de células preenchidas no interior da copa (pCells)	%	40	100	20	20	70	Categórica
<b>Parâmetros ópticos da cena</b>							
Fator de reflectância dos galhos (OBF)	-	0	1	0,5	0,5	1	Categórica
Fator de reflectância do solo (OGF)	-	0	1,5	0,5	0,5	1	Categórica
<b>Parâmetros PROSPECT-5</b>							
Clorofila <i>a+b</i> (C <sub>ab</sub> )	µg/cm <sup>2</sup>	10	100	-	20	40	Contínua
Carotenoides (C <sub>xc</sub> )	µg/cm <sup>2</sup>	5	25	-	5	10	Contínua
Espessura equivalente de água (C <sub>w</sub> )	g/cm <sup>2</sup>	0,002	0,042	-	0,01	0,012	Contínua
Conteúdo de matéria seca (C <sub>m</sub> )	g/cm <sup>2</sup>	0,003	0,033	-	0,005	0,009	Contínua
Parâmetro estrutural da folha (N)	-	1,4	3,4	-	0,5	1,8	Contínua

<sup>a</sup> Incremento da análise de sensibilidade *one-at-a-time* (OAT-SA)

### 4.2.3. Análise de sensibilidade

O conhecimento acerca dos parâmetros que possuem uma pequena ou grande influência no resultado da modelagem (reflectância espectral) auxilia a escolha de variáveis que podem ser estimadas por inversão do modelo. Deseja-se entender como os parâmetros DART influenciam individualmente a resposta espectral da árvore simulada e identificar regiões espectrais mais sensíveis a mudanças nos parâmetros de entrada. Uma análise de sensibilidade do tipo *one-at-a-time* (OAT-SA, do inglês *one-at-a-time sensitivity analysis*) foi realizada e uma série de índices de sensibilidade foram calculados. Os parâmetros do DART foram variados um por vez (*one-at-a-time*) seguindo incrementos específicos e, ao mesmo tempo, mantendo-se os outros parâmetros fixos de acordo com os valores de casos-base (Tabela 4.3), o que resultou em um desenho fatorial de tamanho 56. Para cada simulação foi extraída a reflectância do topo do dossel (TOC, do inglês *Top-Of-Canopy*) de todos os *pixels* contidos em um raio de oito metros do centro da copa. Os resultados da OAT-SA são apresentados pela média e desvio padrão da reflectância dos *pixels* que compunham a árvore simulada. Dessa forma, foi possível obter uma visão geral da influência de cada parâmetro na resposta espectral simulada no TOC. No entanto, para avaliar precisamente essa influência, deve-se quantificar a variância entre simulações que pode ser explicada pela variação de cada parâmetro. Por isso, índices de sensibilidade foram calculados com base na decomposição da análise de variância (ANOVA, do inglês *ANalysis Of VAriance*). O efeito principal ou índice de sensibilidade do parâmetro DART  $z$  na variabilidade dos valores de reflectância de uma determinada banda  $\lambda$  é definido por:

$$SI_z(\lambda) = \frac{SS_z(\lambda)}{SS_T(\lambda)} \quad (4.5)$$

em que  $SS_z(\lambda)$  é a soma de quadrados:

$$SS_z(\lambda) = m \sum_{j=1}^m (\bar{f}_{z_j} - \mu)^2 \quad (4.6)$$

onde  $m$  é o número de categorias considerada para o parâmetro  $z$ ,  $\bar{f}_{z_j}$  é a média da reflectância obtida para a  $j^{\text{ésima}}$  categoria do parâmetro  $z$ , e  $\mu$  é a média de todas as simulações do modelo.  $SS_T(\lambda)$  na Equação 4.5 é a soma de quadrados da decomposição de todos os parâmetros:

$$SS_T(\lambda) = SS_1(\lambda) + \dots + SS_z(\lambda) \quad (4.7)$$

A dinâmica dos índices de sensibilidade para cada parâmetro ao longo do intervalo espectral (VNIR) foi representada graficamente por gráfico de área. Toda análise de sensibilidade foi realizada utilizando o *software* R e o pacote '*multisensi*' (LAMBONI et al., 2011).

#### 4.2.4. Comparação entre dados reais e simulados

##### 4.2.4.1. Filtragem e extração de espectros para a comparação

Os *pixels* extraídos do interior de cada ITC delineado manualmente (Seção 3.4) foram filtrados de modo a descartar aqueles influenciados por sombras. Essa escolha foi motivada pela elevada relação SNR dos *pixels* iluminados (MALENOVSKÝ et al., 2013). Foi definido de forma arbitrária um limiar de reflectância no NIR para diferenciar *pixels* iluminados de sombreados: *pixels* com 20% de reflectância no NIR foram definidos como iluminados. Em seguida, foi calculada a média dos *pixels* iluminados localizados no interior de cada ITC e uma base de dados com 234 espectros foi obtida. De forma semelhante, a resposta espectral média de cada árvore simulada foi calculada, resultando em uma base de dados com 3518 espectros simulados. É importante destacar que as simulações foram realizadas apenas para as espécies que dispunham de dados espectrais adquiridos ao nível foliar (Tabela 3.4), o que totaliza 234 indivíduos (excluindo-se as árvores de *Cecropia hololeuca*, Tabela 4.2) cuja resposta espectral foi obtida ao nível de dossel pelo sensor ProSpecTIR-VS. Os espectros reais e simulados foram então comparados pelo desvio quadrático médio (RMSD, do inglês *Root Mean Square Deviation*) como critério de similaridade espectral:

$$RMSD(\%) = \sqrt{\frac{\sum_{t=1}^n (\rho_{S_t} - \rho_{E_t})^2}{n}} \cdot 100 \quad (4.8)$$

em que  $\rho_{S_t}$  é a reflectância simulada na banda  $t$ ,  $\rho_{E_t}$  é a reflectância experimental na banda  $t$ , e  $n$  é o número de bandas.

A identificação de regiões com pequenas diferenças entre dados simulados e experimentais é importante para avaliar o desempenho do modelo ao longo de toda região espectral estudada e selecionar bandas que podem ser utilizadas em futuras aplicações do modelo. O cálculo do RMSD é uma maneira eficiente de quantificar o poder de simulação ao longo de todo intervalo VNIR, mas é interessante também conhecer, para cada espécie individualmente e para cada comprimento de onda, como a refletância simulada se compara com a reflectância medida. Uma visão geral do desempenho do modelo pode ser obtida pela comparação visual entre espectros simulados e experimentais. Entretanto, necessita-se quantificar diferenças a cada comprimento de onda para se identificar precisamente regiões espectrais com boa/ruim concordância entre medições e simulações. Nesse sentido, para cada espectro mensurado de uma determinada espécie, foram selecionados os 20 espectros simulados mais parecidos (menores valores de RMSD) da LUT, e então, todas as possíveis diferenças ( $D_t$ ) entre o espectro experimental e suas contrapartes simuladas foram calculadas:

$$D_t = (\rho_{S_t} - \rho_{E_t})^2 \quad (4.9)$$

em que  $\rho_{S_t}$  é a reflectância simulada na banda  $t$ ,  $\rho_{E_t}$  é a reflectância experimental na banda  $t$ . Em seguida, RMSD foi computado para cada banda  $t$  como:

$$RMSD_t(\%) = \sqrt{\frac{\sum_{t=1}^N D_t}{N}} \cdot 100 \quad (4.10)$$

onde  $N$  é o número de ITCs por espécie multiplicado por 20 (número de espectros da LUT selecionados para cada espectro experimental).

A inversão de modelos de transferência radiativa por abordagens LUT (Seção 2.3.2.1.2) normalmente é um problema do tipo *ill-posed*, isto é, várias combinações de parâmetros do modelo produzem espectros muito similares e não há garantia de que os parâmetros que resultaram no espectro mais similar seja a melhor solução. Um método comum para resolver este problema é considerar o conjunto de parâmetros que geraram as  $n$  melhores soluções com base em um dado critério (por exemplo, RMSD), e calcular o valor médio dos parâmetros que resultaram tais simulações. Neste trabalho, há também o interesse em conhecer a variabilidade das propriedades da vegetação que resultaram esses  $n$  espectros simulados. Por isso, foi computado o coeficiente de variação (razão entre o desvio padrão e a média) dos mais importantes parâmetros foliares do dossel ( $C_{ab}$ ,  $C_{xc}$ ,  $C_m$  e  $N$ ) que corresponderam aos 20 espectros simulados com menor RMSD para cada espectro experimental.

#### **4.2.5. Definição de métricas para mensuração da similaridade espectral**

##### **4.2.5.1. Importância de atributos**

A identificação de regiões espectrais peculiares com significativo poder discriminante fornece informações valiosas para a classificação de espécies arbóreas utilizando dados hiperespectrais. A resposta espectral das espécies variou consideravelmente nessas regiões e são controladas por vários fatores, incluindo diferenças em propriedades biofísicas e bioquímicas. Pretendeu-se avaliar se as simulações são capazes de preservar adequadamente o poder discriminante das bandas hiperespectrais. Para isso, foi utilizado um procedimento que visou estimar a importância relativa de bandas experimentais e simuladas na discriminação das espécies. O objetivo foi verificar se as regiões espectrais reconhecidas como relevantes para classificar as espécies são as mesmas em dados simulados e experimentais.

O algoritmo *Random Forest* (RF) calcula indicadores de importância de atributos que têm sido amplamente utilizados em aplicações de sensoriamento remoto e ecologia (CHAN; PAELINCKX, 2008; GUO et al., 2011; PAL, 2005). Como detalhado anteriormente (Seção 4.1.2.2), o RF consiste em um conjunto de árvores de decisão, composto por  $n_{tree}$  árvores. A classe de uma amostra é obtida

por um voto majoritário da saída das árvores individuais. Para construir um conjunto de árvores de decisão, o RF cria aleatoriamente novos conjuntos de treinamento, com substituição, reamostrando os dados originais tantas vezes quanto for o número de amostras. Em cada divisão, o método usa apenas um subconjunto aleatório de atributos (bandas) de entrada, composto por  $m_{try}$  bandas, cujo número é previamente definido pelo usuário.

As métricas de importância de atributos, baseiam-se na medida de importância da permutação, também chamada decaimento da exatidão média (MDA, do inglês *mean decrease in accuracy*), ou na impureza de Gini, conhecida como diminuição média do índice de Gini (MDG, do inglês *Mean Decrease in Gini*) (Breiman, 2001). Enquanto a maioria dos estudos anteriores se concentrou no MDA, o presente estudo se dedicou ao MDG, por ter se mostrado mais estável e ter sido aplicada com sucesso a dados espectrais (MENZE et al., 2009; CALLE; URREA, 2011). O MDG é derivado do treinamento do classificador RF. Em cada nó da árvore de decisão, a divisão ótima é buscada de acordo com a impureza de Gini, isto é, uma medida de quão bem uma divisão potencial é capaz de separar as amostras deste nó particular (MENZE et al., 2009). O MDG é então calculado pela soma de todas as diminuições na impureza de Gini a cada divisão do nó, normalizada pelo número de árvores (BREIMAN, 2001; MENZE et al., 2009).

O MDG foi utilizado para conhecer a contribuição de cada banda experimental e simulada para diferenciar as espécies. Primeiramente, com base no critério RMSD, foram selecionados os espectros da LUT mais parecidos com os espectros experimentais. Em seguida, um conjunto balanceado contendo a resposta espectral medida de dez ITCs por espécie foi utilizada para treinar o algoritmo RF, obtendo-se um valor de MDG para cada banda. Apenas dez ITCs por espécie foram selecionados, pois o algoritmo RF tende a favorecer a classe majoritária (CHEN et al., 2004), o que pode levar a resultados errôneos. O MDG foi calculado 100 vezes, mudando-se a cada iteração os ITCs utilizados para treinar o classificador. Isso permitiu com que todos os ITCs fossem considerados, ao mesmo tempo em que se evitou o problema do desbalanceamento de classes. Finalmente, o mencionado procedimento foi repetido com as contrapartes simuladas de cada espectro experimental. Os resultados são mostrados pela média do MDG calculada para as 100 repetições para ambos os dados experimentais e

simulados. Para esse experimento os parâmetros do RF foram fixados em  $n_{tree}=500$  e  $m_{try}=80$ . O pacote ‘*randomForest*’ (LIAW; WIENER, 2002) e ‘*varSelRF*’ (DIAZ-URIARTE, 2007) do R foram utilizados.

#### **4.2.5.2. Separabilidade espectral**

A discriminação de espécies arbóreas tropicais utilizando dados hiperspectrais está intrinsecamente relacionada à separabilidade espectral. Por exemplo, Richter et al. (2016) mostraram que a exatidão da classificação depende da quantidade de variação intraespecífica e uma diferença significativa entre a separabilidade intra e interespecífica. Aqui, a separabilidade espectral intra e interespecífica foi calculada pela distância de Bhattacharyya (KAILATH, 1967) entre pares de espectros, conforme Equação 4.4. A distância de Bhattacharyya foi calculada em dois níveis com todas as 99 bandas VNIR: (i) intraespécie,  $B$  foi calculada para todas as combinações por pares entre os espectros de uma determinada espécie e (ii) interespecie,  $B$  foi calculada para todas as combinações por pares entre os espectros de uma dada espécie e de todas as outras espécies, uma de cada vez. Espectros experimentais e suas contrapartes simuladas foram utilizados para calcular  $B$ , o que permitiu avaliar se o modelo foi capaz de manter a variabilidade espectral presente nos dados experimentais. Estudos anteriores demonstraram uma melhor capacidade da distância de Bhattacharyya para avaliar a separabilidade intra e interespecie arbóreas de florestas tropicais (FÉRET; ASNER, 2013). As diferenças entre os resultados de separabilidade espectral derivados dos espectros simulados e experimentais foram avaliadas utilizando o teste da soma de postos de Wilcoxon.

## 5 RESULTADOS E DISCUSSÃO

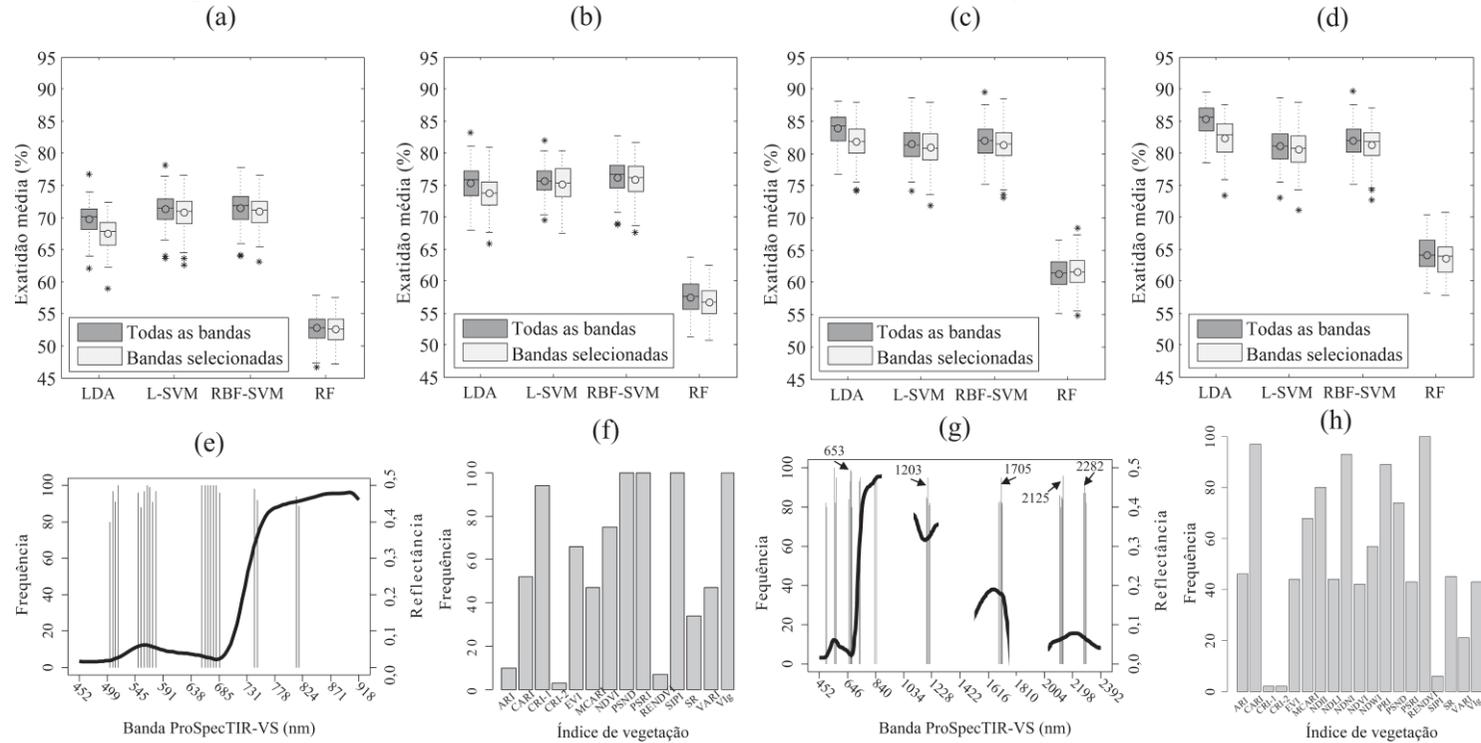
### 5.1. Discriminação e mapeamento de espécies arbóreas

#### 5.1.1. Classificação e variabilidade espectral ao nível de *pixel*

Após repetir a classificação das espécies por 100 vezes, alterando a cada iteração os ITCs que foram usados para o treinamento e teste, verificou-se que a exatidão ao nível de *pixel* foi altamente variável para todos os métodos e regiões espectrais (Figura 5.1). A exatidão de classificação do conjunto de dados I variou entre 47% e 78% (Figura 5.1a), a exatidão dos conjuntos de dados III (Figura 5.1c) e IV (Figura 5.1d) atingiram valores entre 54% e 89%, com o limite inferior correspondendo ao RF em todos os casos testados (I - 99 bandas VNIR; II - 119 bandas VNIR+IVs; III - 260 bandas VNIR+SWIR e IV - 280 bandas VNIR+SWIR+IVs). Essa diferença foi mais notável ao se comparar os resultados de LDA, L-SVM e RBF-SVM. Enquanto a média da exatidão para esses métodos variou de 67% a 71% (Figura 5.1a), a adição de bandas do SWIR elevou a exatidão para o intervalo de 81% a 84% (Figura 5.1c).

A incorporação de canais localizados no SWIR também elevou significativamente a exatidão média das classificações que utilizaram as bandas simuladas do sensor WorldView-3 (Figura 5.2). Enquanto as simulações com 7 bandas VNIR do WV-3 produziram resultados entre 44% e 64%, ao se incluir as 8 bandas SWIR (Figura 4.1) a exatidão de classificação aumentou, ficando entre 54 e 83%, para todos os classificadores testados. Especificamente, o aumento na média foi de aproximadamente 10% para RF e de até 18% para LDA. A relevância de bandas centradas na região do SWIR para discriminação das espécies, observada em dados WV-3 simulados, é corroborada pelo resultado das classificações das imagens reais desse sensor. Nota-se na Figura 5.3 que a exatidão de classificação da maioria das espécies aumentou após a consideração do SWIR, especificamente esse aumento foi de 3.2% da exatidão média. Esses resultados não concordam com estudos recentes realizados em outros tipos de formação florestal. Por exemplo, Dalponte et al. (2013) não verificaram um incremento significativo na exatidão de classificação ao combinar bandas VNIR e SWIR para mapear três

Figura 5.1 – Exatidão média, bandas e IVs selecionados durante o processo de classificação.

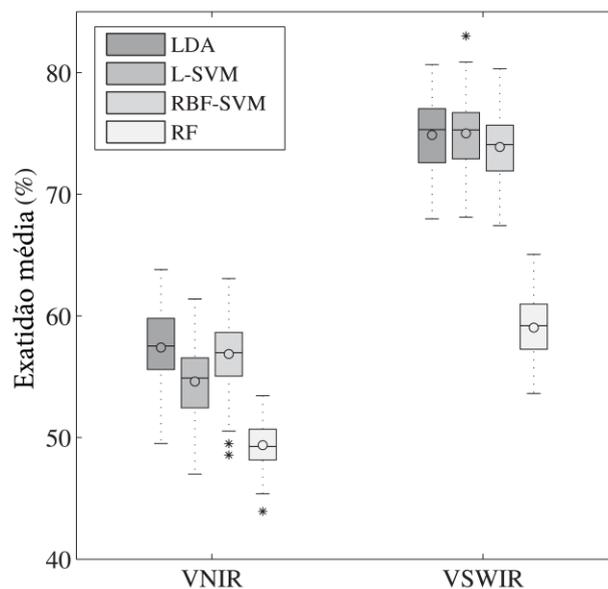


Os *boxplots* (a) - (d) mostram a variabilidade da exatidão de classificação média das espécies arbóreas ao se utilizar Análise Discriminante Linear (LDA), *Support Vector Machines* com *kernel* linear (L-SVM), *kernel* Função de Base Radial (RBF-SVM) e *Random Forest* (RF). As linhas centrais são as medianas e os pontos centrais das caixas são as médias. Os quartis superior e inferior são representados pelas arestas das caixas. A linha tracejada se estende até os pontos de dados mais extremos que não são considerados *Outliers* (discrepantes). *Outliers* são representados individualmente. As classificações foram efetuadas utilizando como entrada todas as bandas ou bandas selecionadas da região do visível/infravermelho próximo (VNIR, 452-919 nm) (a); VNIR mais os Índices de Vegetação (IVs), que foram calculados a partir de bandas VNIR (b); VNIR mais as bandas do infravermelho de ondas curtas (VSWIR, 452-2395 nm) (c); VNIR mais SWIR mais IVs (d). A classificação das espécies arbóreas e a seleção de bandas foram repetidas 100 vezes, alterando-se as árvores utilizadas para treinar e testar os classificadores a cada realização. As frequências das bandas VNIR, VSWIR e IVs selecionadas são mostradas em (e), (f), (g) e (h). A resposta espectral média da *Croton piptocalyx* é representada graficamente em (e) e (g) para maior clareza.

Fonte: Produção do autor.

espécies arbóreas dominantes em uma floresta boreal. As principais razões destacadas pelos autores foram a resolução espacial dos dados SWIR e sua baixa relação SNR quando comparado com os dados do VNIR. É importante destacar que os autores utilizaram um sensor que operava na região do SWIR entre 900 e 1700 nm. O procedimento de seleção de bandas empregado neste trabalho sugere que, não apenas as bandas ao redor de 1700 nm são relevantes para discriminação das espécies, mas também, as localizadas ao redor de 2100 e 2300 nm (Figura 5.1g).

Figura 5.2 – Exatidão média de classificação obtida com bandas simuladas do sensor WorldView-3.

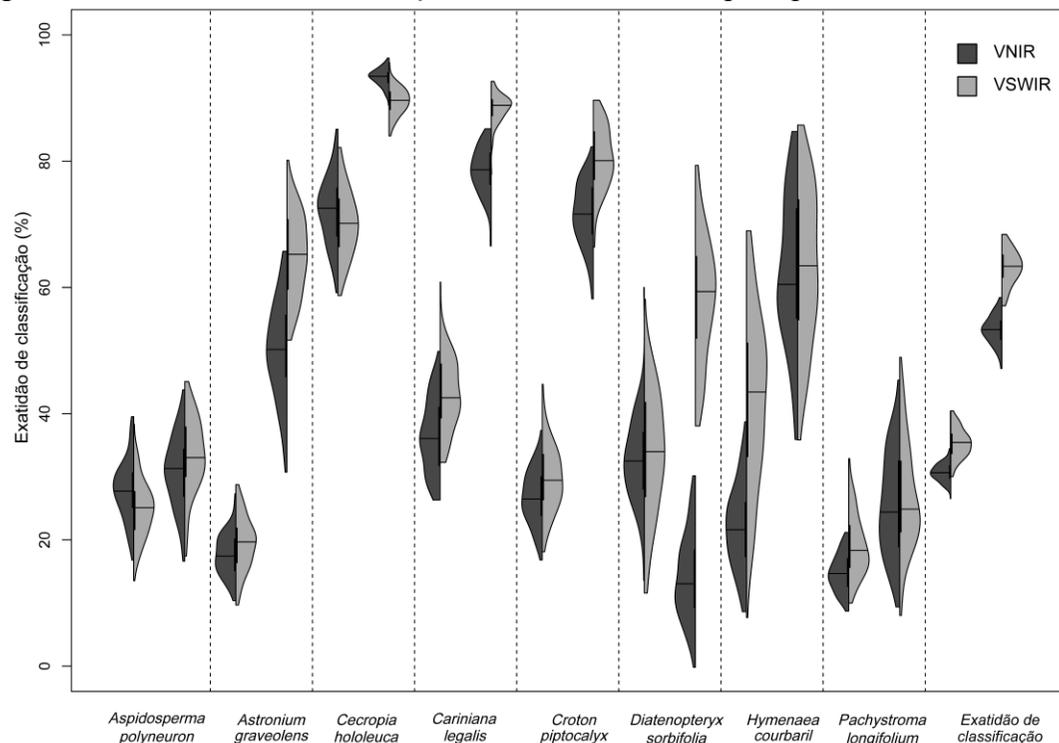


Os *boxplots* mostram a variabilidade da exatidão de classificação das espécies arbóreas (Tabela 4.2). As linhas centrais são as medianas, e os pontos centrais das caixas são as médias. Os quartis superior e inferior são representados pelas arestas das caixas. A linha tracejada se estende até os pontos de dados mais extremos que não são considerados *Outliers* (discrepantes). *Outliers* são representados individualmente. As classificações foram repetidas 100 vezes, alterando-se as árvores utilizadas para treinar e testar os classificadores. Os métodos testados foram: Análise Discriminante Linear (LDA), *Support Vector Machines* com *kernel* linear (L-SVM), *kernel* Função de Base Radial (RBF-SVM) e *Random Forest* (RF). Sete bandas do visível/infravermelho próximo (VNIR, 452-919 nm) e 15 bandas que englobavam o VNIR e o infravermelho de ondas curtas (VSWIR, 452-2395 nm) simuladas do sensor WorldView-3 foram utilizadas nas classificações.

Fonte: Produção do autor.

Isso indica que as espécies possuem variações espectrais importantes nessas regiões espectrais, o que pode ser sustentado pelos resultados da incorporação de IVs no processo de classificação. O *Normalized Difference Nitrogen Index* (NDNI, SERRANO et al. (2002)), que é calculado utilizando bandas do SWIR, foi um dos índices mais

Figura 5.3 – Exatidão de classificação obtida com dados hiperespectrais e WorldView-3.



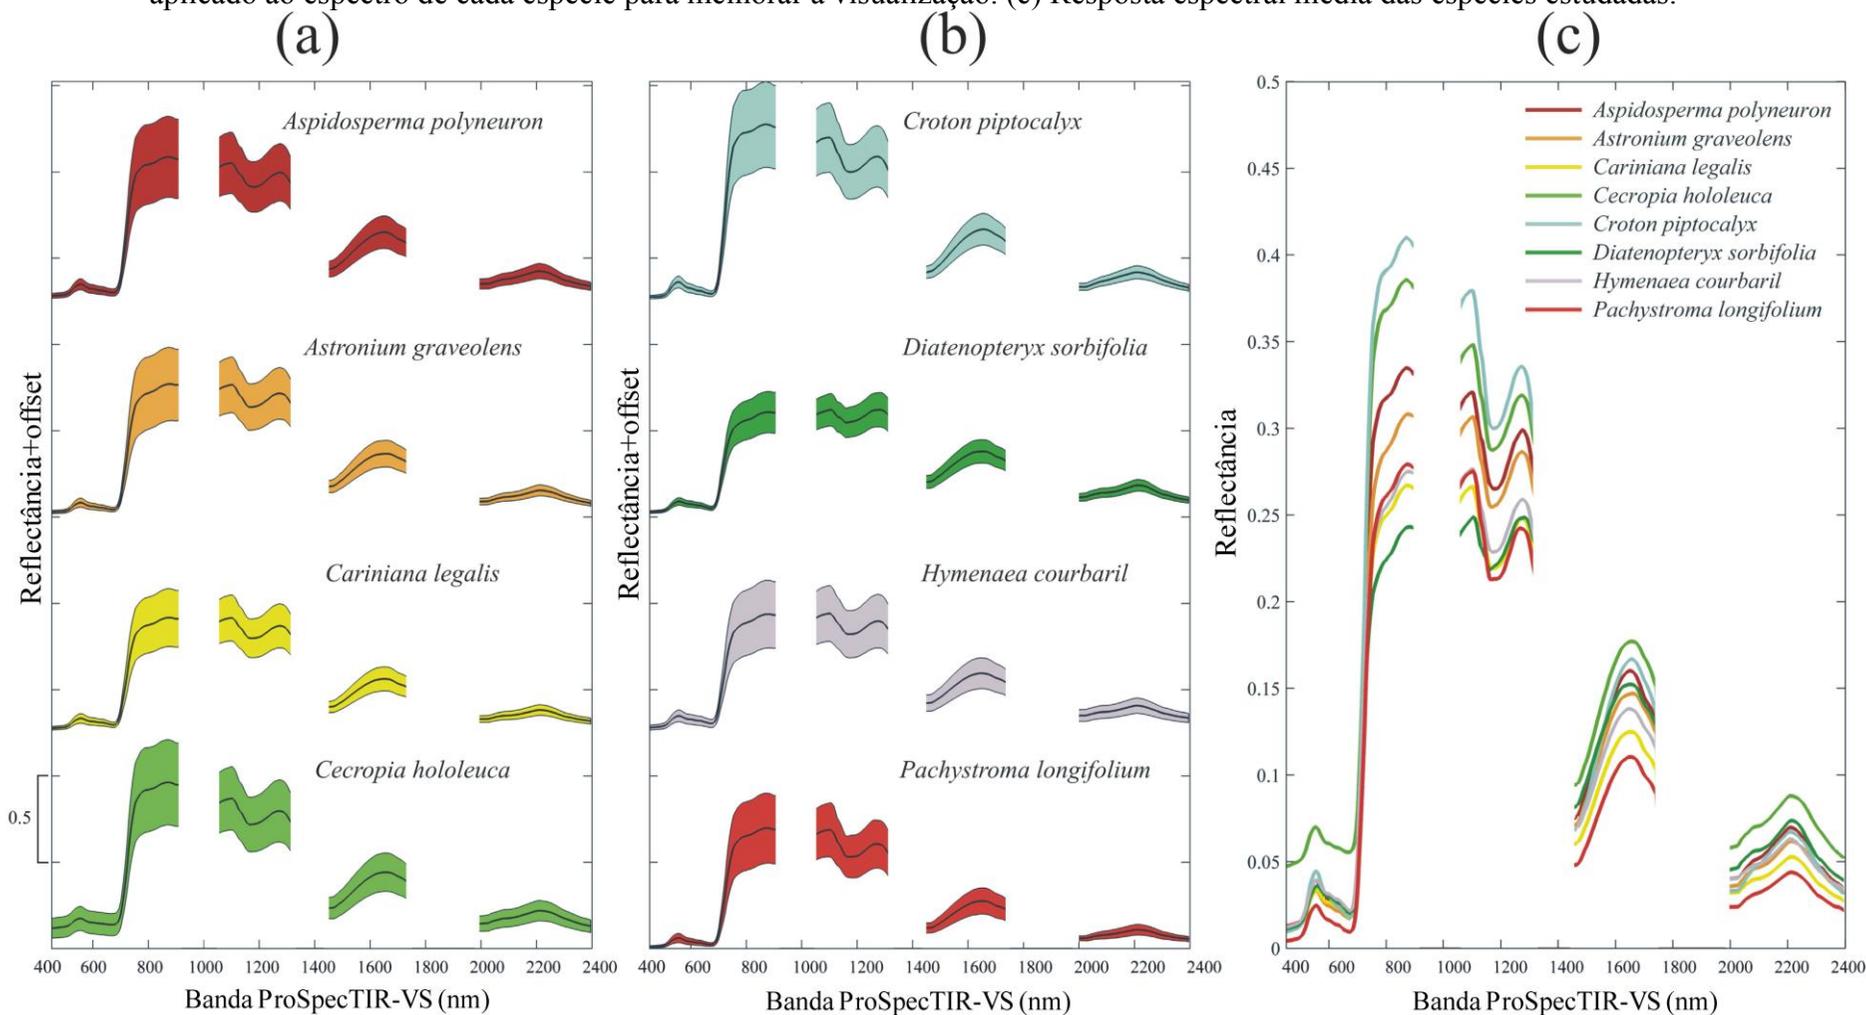
Gráficos do tipo violino que mostram a variabilidade da exatidão de classificação das espécies arbóreas (Tabela 4.2) ao se utilizar imagens hiperespectrais e imagens reais do sensor WorldView-3 (WV-3). A linha horizontal é a mediana, e a linha vertical em negrito representa a intervalo interquartil. Os gráficos se estendem de acordo com a distribuição dos dados. O método de classificação foi o *Random Forest*. As classificações foram repetidas 100 vezes, alterando-se as árvores utilizadas para treinar e testar o classificador. Foram utilizadas sete e 99 bandas da região do visível/infravermelho próximo (VNIR, 450-1040 nm) do satélite WV-3 e do sensor hiperespectral aerotransportado ProSpecTIR-VS, respectivamente. Para classificações com bandas na região do VNIR e infravermelho de ondas curtas (VSWIR, 450-2395 nm), empregou-se 15 bandas WV-3 e 260 bandas hiperespectrais.

Fonte: Produção do autor.

frequentemente selecionados durante as classificações (Figura 5.1h). As bandas ao redor de 2100 e 2300 nm apresentam feições de absorção importantes que estão relacionadas à concentração de constituintes bioquímicos não pigmentados como nitrogênio, celulose e lignina, particularmente na vegetação seca (KOKALY et al., 2009). Kokaly et al. (2001) mostraram que incrementos na concentração de nitrogênio altera a reflectância de folhas secas em 2100 nm. Tal alteração advém de duas outras feições de absorção centradas em 2054 nm e 2172 nm, e estão relacionadas a compostos nitrogenados das plantas, como as proteínas. Mais especificamente, Elvidge (1990) notou que o espectro da proteína ribulose-1-5-bisfosfato carboxilase oxigenase (rubisco) possui feições de absorção próximas a esses comprimentos de onda. A rubisco é responsável por 30 a 50% do nitrogênio presente em folhas verdes e é considerada a principal enzima do processo de fotossíntese (ELVIDGE, 1990). Celulose e lignina também contribuem para a forma das feições de absorção em 1700 nm, 2100 nm e 2300 nm. Esses compostos desempenham papel fundamental na estrutura e suporte dos tecidos das plantas vasculares, conferindo rigidez à parede celular. Serrano et al. (2002) encontraram relações estatísticas razoáveis ( $r^2=0,44-0,58$ ) entre a concentração de lignina da folha e a reflectância espectral em 1754 nm de áreas de florestas mediterrâneas. Celulose e lignina são abundantes na serapilheira, exercendo forte influência na decomposição da matéria orgânica e ciclagem de nutrientes.

Acredita-se que as variações na reflectância do SWIR entre 1700 nm, 2100 nm e 2300 nm foram devidas à deciduidade das espécies arbóreas da área de estudo. Alguns indivíduos emergentes, como *CL* e *AG*, podem perder grande parte das folhas, expondo o solo da floresta, que é composto em grande parte por serapilheira. Outra região espectral importante do SWIR, identificada pelo procedimento de seleção de bandas, localiza-se ao redor de 1200 nm (Figura 5.1g). Gao (1996) foi um dos primeiros pesquisadores a utilizar a feição de absorção em 1200 nm para monitorar a quantidade de água de dosséis por sensoriamento remoto, propondo o NDWI (Tabela 4.1). Mais recentemente, Asner et al. (2004) utilizaram a feição de água em 1200 nm para estimar a condição da água do dossel da floresta amazônica. No presente estudo, o NDWI e as bandas ao redor de 1200 nm foram importantes na discriminação das espécies (Figura 5.1h,g), indicando concentrações variadas de água entre os ITCs. Diferenças na feição de absorção da água a 1200 nm são visíveis na resposta espectral das espécies

Figura 5.4 – (a)-(b) Média (linhas em negrito)  $\pm$  1 envelopes de desvio padrão da resposta espectral das espécies arbóreas. Um offset de 0,5 foi aplicado ao espectro de cada espécie para melhorar a visualização. (c) Resposta espectral média das espécies estudadas.

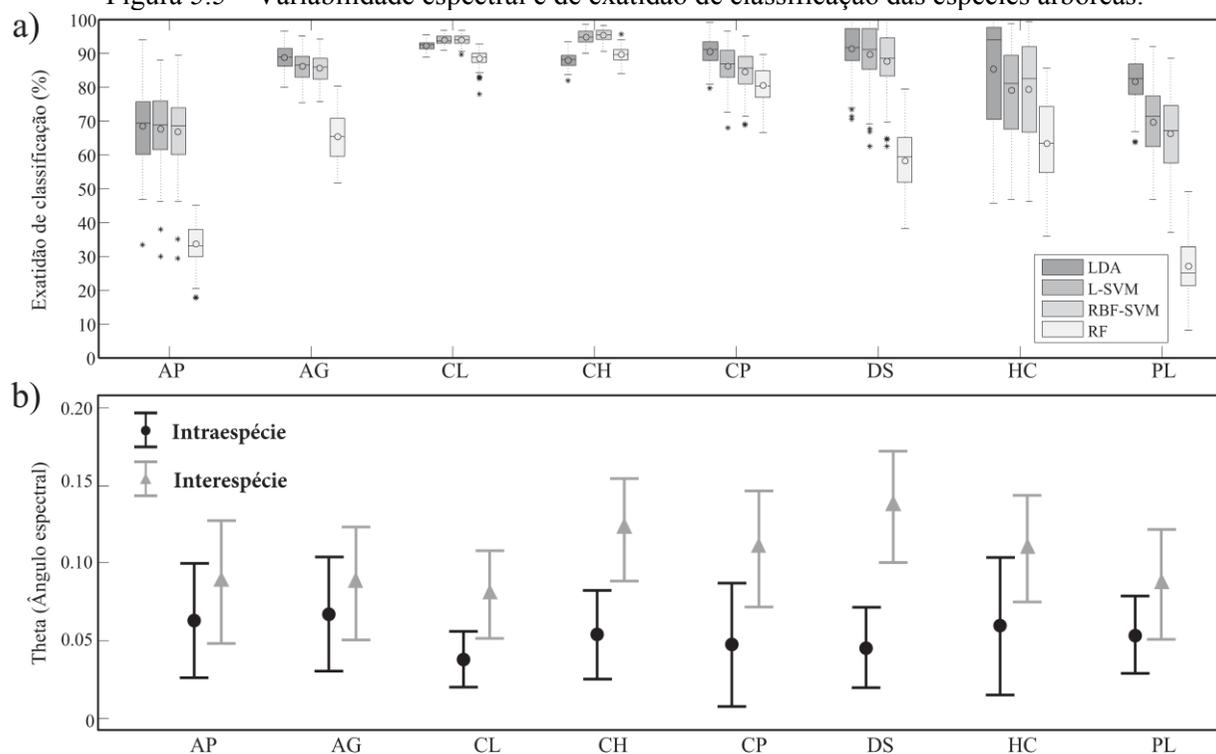


Fonte: Produção do autor.

(Figura 5.4). Por exemplo, *Croton piptocalyx* apresenta uma feição em 1200 nm mais profunda se comparada à *Cariniana legalis* ou *Diatenopreryx sorbifolia*. Os índices de vegetação, quando combinados com bandas VNIR, aumentaram significativamente a exatidão de classificação das espécies arbóreas em até 5% (Figura 5.1b). Este é um resultado importante, pois na indisponibilidade de bandas do SWIR, o cômputo de IVs pode melhorar a discriminação. Os índices selecionados com maior frequência foram VIg, seguido por PSND, PSRI e SIPI. Como mostra a Tabela 4.1, esses índices estão relacionados a características estruturais e bioquímicas das espécies. VIg, também conhecido como NDVI verde, é a razão normalizada entre as bandas do vermelho e verde, sendo fortemente relacionado à fração de vegetação e IAF (GITELSON et al., 2002a). PSND, PSRI e SIPI estão relacionados a mudanças na razão entre carotenoides e clorofilas devido à senescência das folhas. Durante a senescência, todos os pigmentos fotossintéticos declinam com uma maior perda de clorofilas do que carotenoides, resultando em uma alta retenção deste composto na folha (BISWAL, 1995). Os resultados obtidos com seleção de bandas e IVs foram consistentes com os processos que ocorrem na vegetação da área de estudo, em que as espécies arbóreas naturalmente tendem a perder folhas durante a estação seca. As imagens hiperespectrais provaram ser uma importante fonte de informação sobre esse fenômeno, que influencia a composição e a estrutura da FES (SOUZA et al., 2014).

As espécies arbóreas da FES podem apresentar padrões distintos de queda de folhas, o que depende do próprio indivíduo ou das condições ambientais em que ele está inserido (MORELATTO, 1991). Isso teve impacto na variabilidade espectral das espécies, quantificada aqui pelo ângulo espectral  $\theta$  (Equação 2.2). Os resultados mostram que há uma forte relação entre a exatidão de classificação e a variabilidade espectral intra e interespecífica. Por exemplo, *CL*, quando comparada a *HC*, apresentou baixa dispersão dos valores de exatidão (Figura 5.5a). Nota-se que o ângulo espectral  $\theta$  (Equação 2.2) mostrou uma variabilidade menor entre copas de *CL* do que entre indivíduos de *HC* (Figura 5.5b). Na realidade, a exatidão de classificação atingiu os valores mais altos para as espécies com maiores diferenças entre as métricas  $\theta$  determinadas intra e interespecificamente. Esse resultado pode ser claramente constatado ao se comparar *AP* e *DS* (Figura 5.5b). Considerando que a diferença entre os valores médios de  $\theta$  foi de 0,02 rad para *AP*, a mesma diferença para *DS* atingiu 0,09 rad. Observando-se LDA, L-SVM e RBF-SVM, as médias da exatidão variaram de 87,5% a 91,2% para *DS* e de

Figura 5.5 – Variabilidade espectral e de exatidão de classificação das espécies arbóreas.



(a) *Boxplots* que mostram a variabilidade da exatidão de classificação das espécies arbóreas (Tabela 4.2). As linhas centrais são as medianas, e os pontos centrais das caixas são as médias. Os quartis superior e inferior são representados pelas arestas das caixas. A linha tracejada se estende até os pontos de dados mais extremos que não são considerados *Outliers* (discrepantes). *Outliers* são representados individualmente. As classificações foram repetidas 100 vezes, alterando-se as árvores utilizadas para treinar e testar os classificadores. Os métodos testados foram: Análise Discriminante Linear (LDA), *Support Vector Machines* com *kernel* linear (L-SVM), *kernel* Função de Base Radial (RBF-SVM) e *Random Forest* (RF). Todas as bandas das regiões do visível/infravermelho próximo e infravermelho de ondas curtas (VSWIR, 452-2395 nm) foram utilizadas no processo de classificação. (b) Média  $\pm 1$  desvio padrão do ângulo espectral em radianos (Equação 2.2), calculado intra e interespécies utilizando as 260 bandas VSWIR.

Fonte: Produção do autor.

66,8% a 68,5% para *PA*. Os efeitos da variabilidade espectral intra e interespecífica na exatidão de classificação de espécies arbóreas tropicais é pouco conhecida. Estudos anteriores, realizados ao nível foliar, mostraram que existe um elevado grau de sobreposição entre essas duas medidas, o que coloca em cheque a viabilidade de dados hiperespectrais para discriminar espécies de árvores (CASTRO-ESSAU et al., 2006; FÉRET; ASNER, 2011). Ao nível de dossel, apesar da elevada exatidão (73%) obtida na classificação de 17 espécies arbóreas em uma floresta havaiana, Féret e Asner (2013) relataram ângulos espectrais muito semelhantes calculados intra e interespecificamente. No estudo aqui apresentado, as espécies exibiram distintos graus de sobreposição entre as métricas  $\theta$  (Figura. 5.5b), o que se relacionou ao desempenho dos métodos de classificação. Por exemplo, *AP* mostrou o maior grau de sobreposição entre os valores de  $\theta$ , resultando na exatidão de classificação média mais baixa (~ 69% para LDA, L-SVM e RBF-SVM). Em geral, quanto maior a diferença entre a variabilidade intra e interespecífica, maior a exatidão da classificação. No entanto, a capacidade do classificador em prever a classe de amostras desconhecidas também depende da quantidade de variabilidade intraespecífica. Espécies com baixas variações na exatidão apresentaram, também, baixas variações intraespecíficas de  $\theta$ , o que pode ser visto claramente na Figura 5.5 para *CL*.

Em relação aos métodos de classificação, LDA, L-SVM e RBF-SVM mostraram desempenhos similares, particularmente ao se utilizar os conjuntos de dados III (Figura 5.1c) e IV (Figura 5.1d), com LDA superando os outros classificadores e RF exibindo os piores resultados. O procedimento de seleção de bandas não influenciou expressivamente os resultados da classificação (valor-p do teste da soma de postos de Wilcoxon = 0,21; Figura 5.1a,b,c,d,e), mas foi importante no auxílio ao reconhecimento de regiões espectrais relevantes para a discriminação das oito espécies estudadas, como detalhado anteriormente. Em quase todos os casos, LDA superou SVM, sendo, todavia, o método mais afetado pela dimensionalidade dos dados. A seleção de bandas reduziu o desempenho da LDA nos casos testados (Figura 5.1a, b, c, d), o que era esperado visto que o método utiliza toda informação disponível para maximizar a separabilidade entre as classes, aplicando uma transformação do espaço de atributos original (BANDOS et al., 2009). Dalponte et al. (2009) também observaram o decréscimo na exatidão

de classificação da LDA após reduzir o número de bandas para analisar imagens hiperespectrais adquiridas sobre uma floresta temperada.

De forma não usual, LDA, um método relativamente simples, superou o SVM com ambos os *kernels* linear e função de base radial. Exceto para um número menor de bandas VNIR, L-SVM e RBF-SVM produziram melhores resultados do que a LDA (Figura 5.1a), indicando que o SVM, nesse caso, produziu melhores hiperplanos de separação, mesmo com uma quantidade reduzida de atributos. Entretanto, quando a dimensionalidade dos dados aumentou pela adição de bandas SWIR, a exatidão do SVM permaneceu abaixo da LDA. Segundo Pal e Foody (2010) o desempenho do SVM na classificação de imagens hiperespectrais não está imune ao fenômeno de Hughes (HUGHES, 1968) e o procedimento de seleção de bandas não melhorou a exatidão de classificação de forma significativa (Figura 5.1a,b,c,d). Por isso, a LDA parece exibir uma melhor capacidade de generalização do que o SVM para classificar ITCs desconhecidos no elevado espaço dimensional testado (260 bandas VSWIR), ao menos para o conjunto de espécies e quantidade de amostras de treinamento consideradas neste estudo.

O desempenho do RF foi consistentemente pior do que os outros métodos, sugerindo que as árvores de decisão inicialmente geradas durante o processo de treinamento não foram suficientemente acuradas para serem combinadas com sucesso. Provavelmente isso decorre do fato das espécies serem espectralmente muito similares. Além disso, o RF tendeu a favorecer as classes majoritárias (com o maior número de *pixels*), o que foi observado também por Chen (2004). Pelos resultados da classificação de *CL* (Figura 5.5a) é possível perceber que o desempenho do RF é similar ao dos outros métodos. Por outro lado, no caso do *PL*, que possui um número menor de amostras (Tabela 4.2), os resultados do RF, em relação a LDA, L-SVM e RBF-SVM, foram muito inferiores. Pesquisas anteriores que lidaram com a classificação de espécies arbóreas também relataram esse problema com relação ao método RF (DALPONTE et al., 2013).

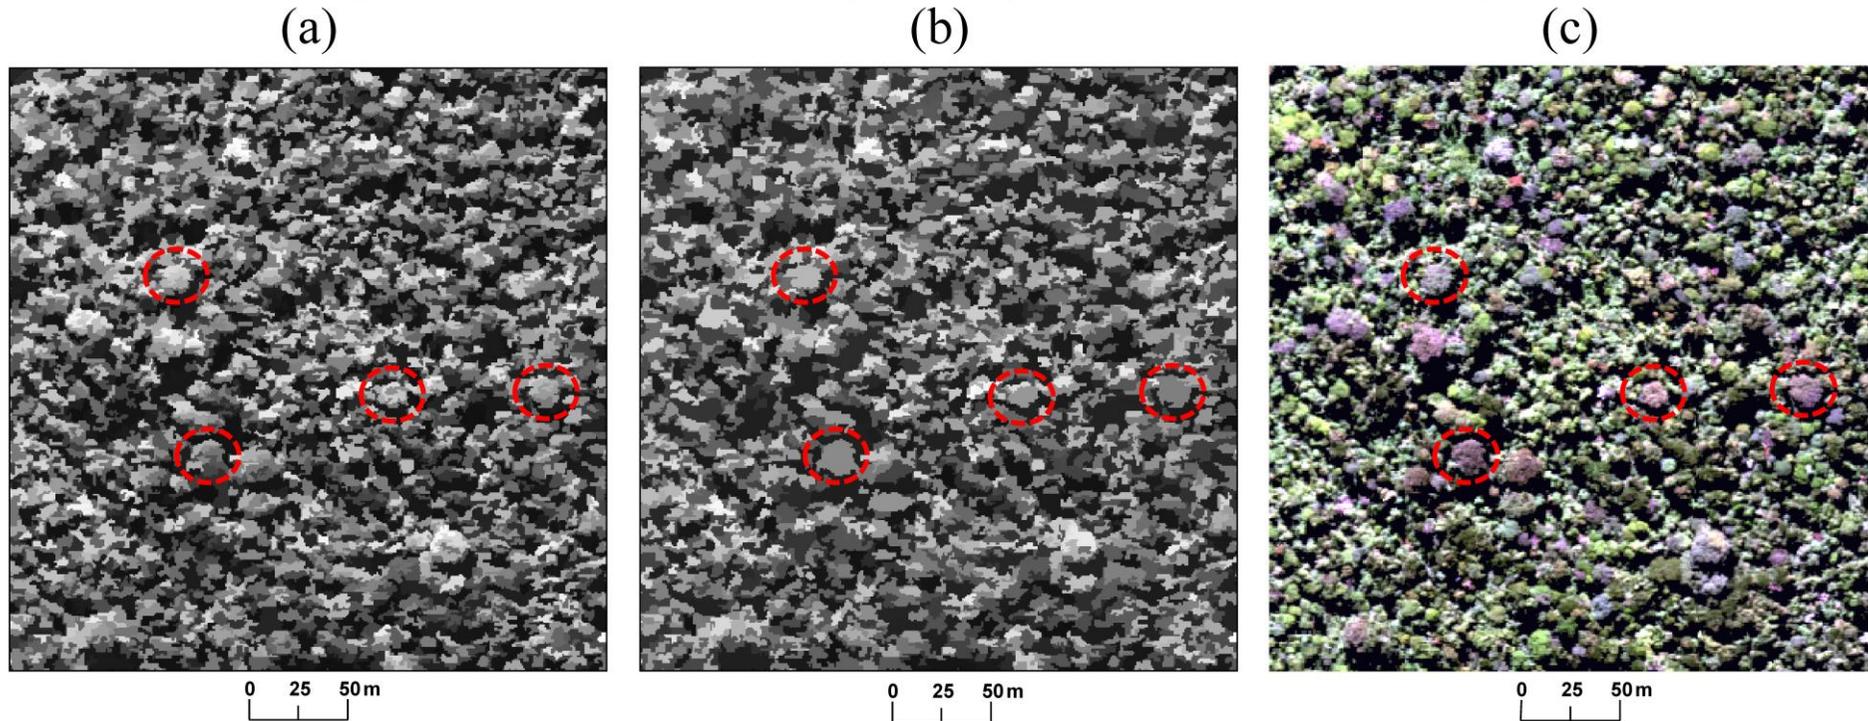
### **5.1.2. Mapas de espécies arbóreas**

A Tabela 5.1 mostra a exatidão média de classificação por espécie nos mapas produzidos pelos métodos utilizados. A classificação hiperespectral utilizou todas

as bandas VSWIR (conjunto de dados III). A LDA obteve as maiores exatidões, seguida por L-SVM, RBF-SVM e RF. Em comparação com as bandas multiespectrais simuladas do WV-3, os dados hiperespectrais elevaram a exatidão média de 6,2% (RBF-SVM) para 8,9% (LDA) (Tabela 5.1). Os métodos testados mostraram desempenhos diferentes ao mapear as espécies. Embora o LDA tenha atingido a maior exatidão média, gerou o resultado mais pobre para o mapeamento de *CH*, que foi melhor detectada por RBF-SVM. Além disso, o RBF-SVM mapeou corretamente o maior número de ITCs de validação (84,9%, Tabela 5.1). É importante destacar que, enquanto a exatidão média ao nível de *pixel* variou de 82% a 84% para LDA, L-SVM e RBF-SVM (*boxplots* na Figura 5.1), a abordagem orientada a objetos elevou a exatidão do mapeamento para 85,8% a 90,1% (Tabela 5.1). Isso demonstra que o método de segmentação desenvolvido foi eficaz para abordar o problema em questão. Na prática, verificou-se que a utilização da distância JM (Equação 4.3) uniu segmentos espectralmente semelhantes no interior de uma mesma copa. A Figura 5.6 mostra os resultados do método. Na primeira etapa (Figura 5.6a), nota-se que as copas das árvores sofreram um processo de super-segmentação que diminuiu após a junção de segmentos vizinhos espectralmente semelhantes (Figura 5.6b). Percebe-se claramente que o método, a partir da informação presente nas bandas hiperespectrais, conseguiu unir segmentos distintos pertencentes ao mesmo indivíduo, melhorando o delineamento de copas e elevando a exatidão de classificação.

A Tabela 5.1 apresenta a porcentagem média de ITCs do conjunto de teste com mais de 80% dos *pixels* interiores corretamente classificados. LDA, quando aplicada às bandas WV-3, mapeou 69,7% dos ITCs, enquanto que RBF-SVM elevou o mapeamento para 84,9%, utilizando as bandas hiperespectrais. Em comparação com os dados multiespectrais simulados, os dados hiperespectrais mapearam 5,3% mais ITCs com L-SVM, atingindo um aumento de até 13,1% com LDA. A exatidão média do usuário variou de 64,6% a 87,1% e a exatidão média do produtor variou de 68,1% a 87,2%. A Figura 5.7 mostra os mapas de espécies que foram produzidos com a utilização de todos os 273 ITCs para treinar os classificadores. A abordagem proposta produziu mapas realísticos por meio de segmentação da imagem, da regra de decisão (Equação 4.1) e, conseqüentemente,

Figura 5.6 – Resultados do método de segmentação aplicado à classificação orientada a objetos.



(a) Super-segmentação de uma composição colorida em cor verdadeira da imagem hiperespectral ( $R = 639 \text{ nm}$ ,  $G = 548 \text{ nm}$ ,  $B = 460 \text{ nm}$ ); (b) Segmentação resultante da aplicação da distância de Jeffreys-Matusita (Equação 4.3), calculada com todas as bandas hiperespectrais, para unir segmentos espectralmente semelhantes; (c) Composição colorida em cor verdadeira da imagem hiperespectral ( $R = 639 \text{ nm}$ ,  $G = 548 \text{ nm}$ ,  $B = 460 \text{ nm}$ ). Os círculos em vermelho representam copas de árvores na imagem.

Fonte: Produção do autor.

a rotulação apenas dos *pixels* de alta probabilidade de pertencer a uma determinada classe.

Tabela 5.1 – Exatidão média de classificação (%) para 100 mapas de espécies arbóreas, produzidos com diferentes copas de treinamento e teste, utilizando os métodos Análise Discriminante Linear (LDA), *Support Vector Machines* com *kernel* linear (L-SVM), *kernel* Função de Base Radial (RBF-SVM) e *Random Forest* (RF). Os códigos das espécies foram disponibilizados na Tabela 4.2.

Espécie	Método de classificação							
	LDA		L-SVM		RBF-SVM		RF	
	Hiperspectral	WV-3	Hiperspectral	WV-3	Hiperspectral	WV-3	Hiperspectral	WV-3
AP	72,8	65,4	70,4	64,2	71,2	66,3	38,1	33,4
AG	93,0	85,8	89,0	84,3	89,5	84,4	69,7	63,2
CL	96,6	80,3	97,5	91	97,4	91,3	92,9	89,9
CH	92,2	86,2	98,3	96,5	98,7	96,1	94,0	88,6
CP	94,8	86,2	88,0	84,9	89,6	88,1	85,0	79,1
DS	95,5	87,9	91,1	83,6	93,2	86,2	62,8	52,1
HC	89,6	86,1	82,7	70,7	82,5	72,7	67,8	56,4
PL	85,9	71,4	69,5	59,8	73,1	60,6	31,4	26,5
EM <sup>a</sup>	90,1	81,2	85,8	79,4	86,9	80,7	67,7	61,1
ITCs <sup>b</sup>	82,8	69,7	81,5	76,2	84,9	78,5	57,3	51,1
EU <sup>c</sup>	87,1	79,5	81,6	79,3	84,7	81,8	65,5	64,6
EP <sup>d</sup>	82,8	71,7	87,2	76,0	81,2	77,0	70,8	68,1

<sup>a</sup>EM=Exatidão Média (%).

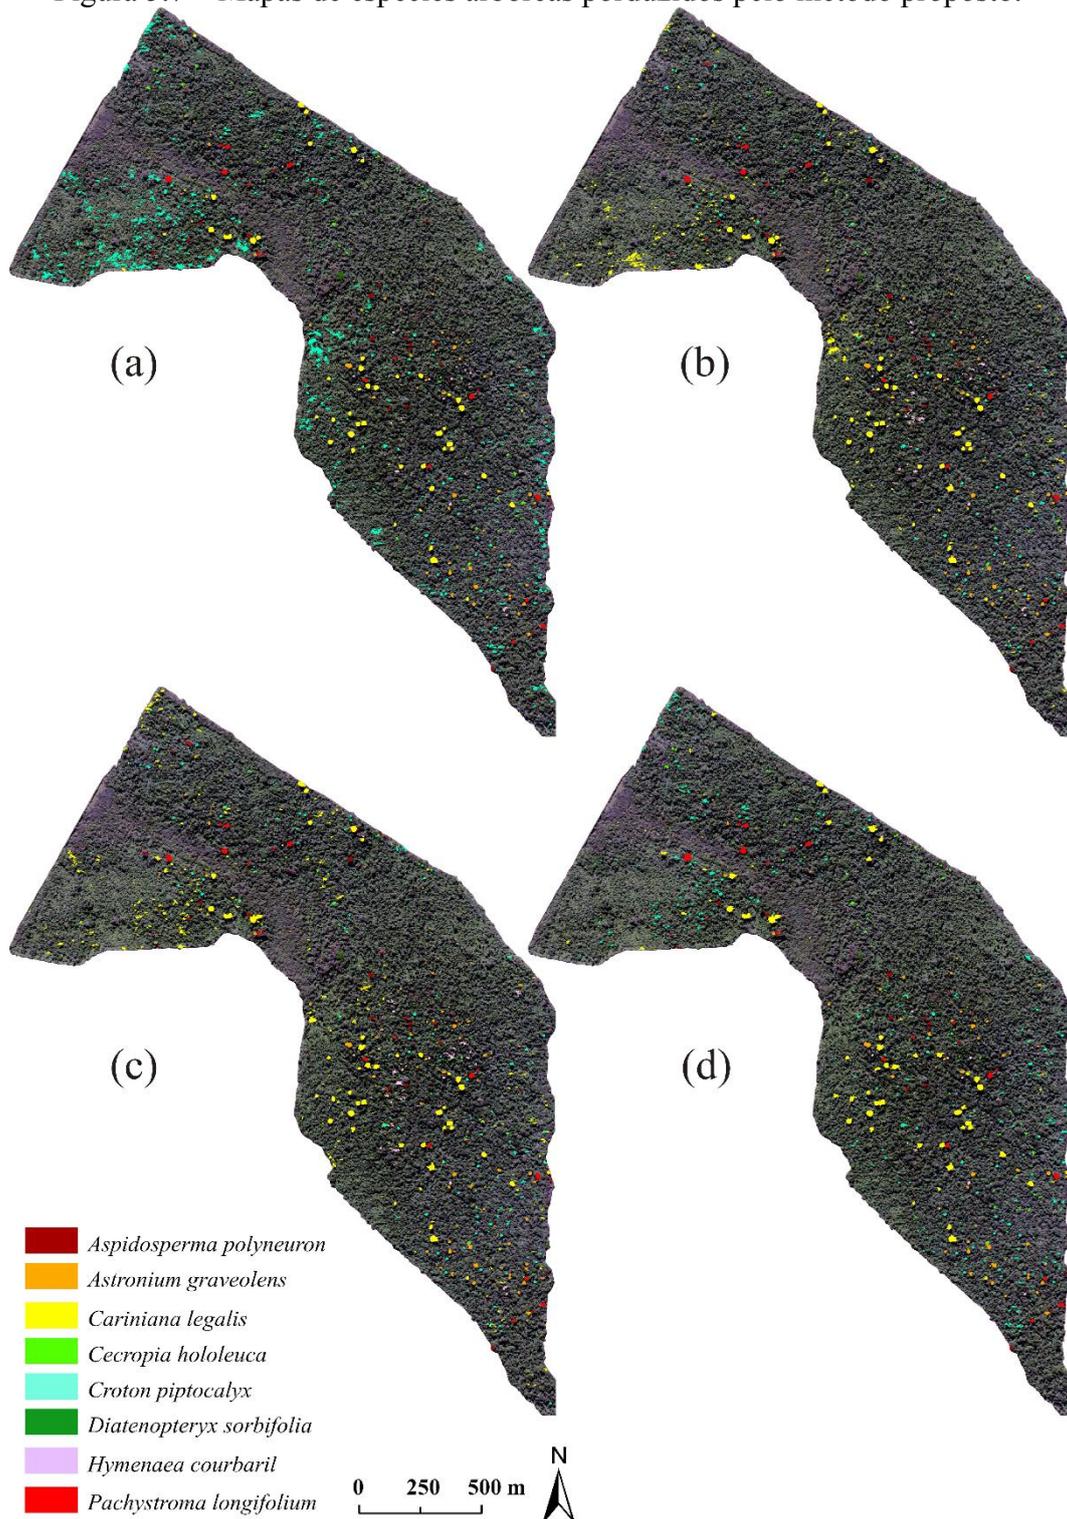
<sup>b</sup>ITCs=Porcentagem de ITCs do conjunto de teste com mais de 80% dos *pixels* em seu interior corretamente classificados.

<sup>c</sup>EU=Exatidão média do usuário (%).

<sup>d</sup>EP= Exatidão média do produtor (%).

A abordagem de classificação orientada a objetos desenvolvida neste trabalho provou ser útil para mapear a distribuição espacial de espécies pioneiras e emergentes de forma fidedigna. Algumas delas como *Aspidosperma polyneuron*, *Cariniana legalis* e *Hymenea courbaril*, foram intensivamente exploradas devido à elevada qualidade da madeira e são atualmente consideradas espécies ameaçadas. Mapas dessas espécies poderão ser utilizados por gestores florestais na localização de indivíduos representativos para coleta de material biológico visando à produção de mudas. A detecção de árvores matrizes para coleta de sementes constitui uma parte relevante dos custos dos programas de restauração florestal. Além disso, demonstrou-se que o monitoramento dessas espécies clímax é importante para identificar sinais de desestruturação florestal, de modo que

Figura 5.7 – Mapas de espécies arbóreas produzidos pelo método proposto.



Mapas produzidos por (a) Análise Discriminante Linear (LDA), *Support Vector Machines* com *kernel* linear (L-SVM) (b), *kernel* Função de Base Radial (RBF-SVM) (c) e *Random Forest* (RF) (d), utilizando todas as bandas hiperespectrais. Uma composição colorida em cor verdadeira (R=639 nm, G=548 nm, B=460 nm) de tonalidade escura foi inserida no fundo de cada mapa para melhorar a visualização.

Fonte: Produção do autor.

esforços possam ser feitos para restaurar o ecossistema enquanto sua resiliência ainda existe (FARAH et al., 2014).

## **5.2. Simulação da resposta espectral de espécies arbóreas**

Nesta seção serão apresentados e discutidos os resultados da modelagem de transferência radiativa em 3D que foi utilizada para simular a resposta espectral das espécies arbóreas ao nível de dossel.

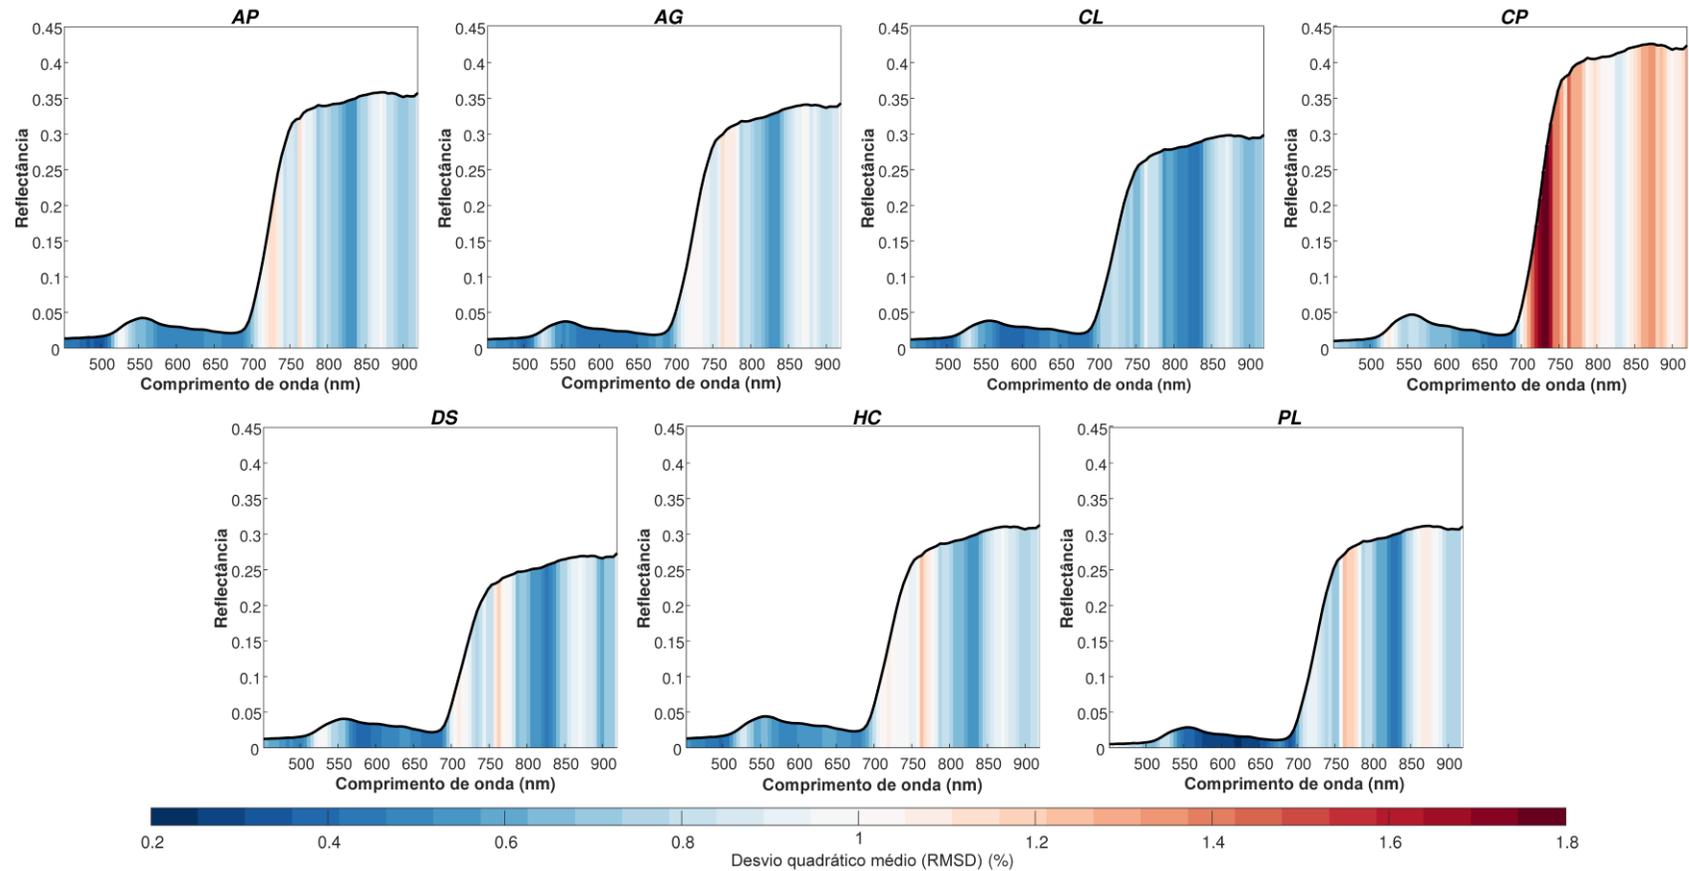
### **5.2.1. Similaridade espectral e inversão da *Look-Up-Table***

As diferenças entre os espectros experimentais e suas respectivas contrapartes simuladas variaram entre 0,2 a 1,8% ao longo do intervalo VNIR. De forma mais específica, o RMSD atingiu valores entre 0,2 a 1% no visível (VIS, 450-700 nm), 0,5 a 1,8% na borda do vermelho (RE, do inglês *red edge*; 700-750 nm) e 0,4 a 1,4% no infravermelho próximo (NIR, 750-920 nm) (Figura 5.8). No VIS, vale destacar que a resposta espectral das espécies apresentou valores de RMSD relativamente elevados ao redor de 525 nm. Por exemplo, para AP o RMSD atingiu cerca de 0,9% entre 520 e 538 nm, enquanto que para o restante do domínio VIS ele não excedeu 0,5%.

Como visto, a melhor concordância entre os dados reais e simulados ocorreu na região do VIS, onde os valores de RMSD não ultrapassaram 1%. No VIS, as propriedades ópticas do dossel são controladas principalmente por pigmentos foliares que absorvem a luz incidente. Malenovský et al. (2013) utilizaram espectros simulados pelo DART na faixa de 650-720 nm para extrair a concentração de clorofila ( $C_{ab}$ ) de uma área de floresta temperada. Nessa faixa espectral, a estratégia de simulação aqui desenvolvida se mostrou eficaz para reproduzir a reflectância das espécies, mostrando, portanto, potencial para extração de  $C_{ab}$  a partir de dados hiperespectrais. De maneira geral, os espectros simulados e reais apresentaram uma melhor concordância no VIS do que no NIR.

Os altos valores de RMSD obtidos para as bandas NIR são oriundos, logicamente, da discordância entre os dados experimentais e simulados, e podem ser visualizados pela representação gráfica da resposta espectral das espécies nas duas bases de dados (Figura 5.9). A discordância mais acentuada foi encontrada ao

Figura 5.8 – Desvio quadrático médio (RMSD) (%) entre a resposta espectral experimental e simulada de sete espécies arbóreas da área de estudo.



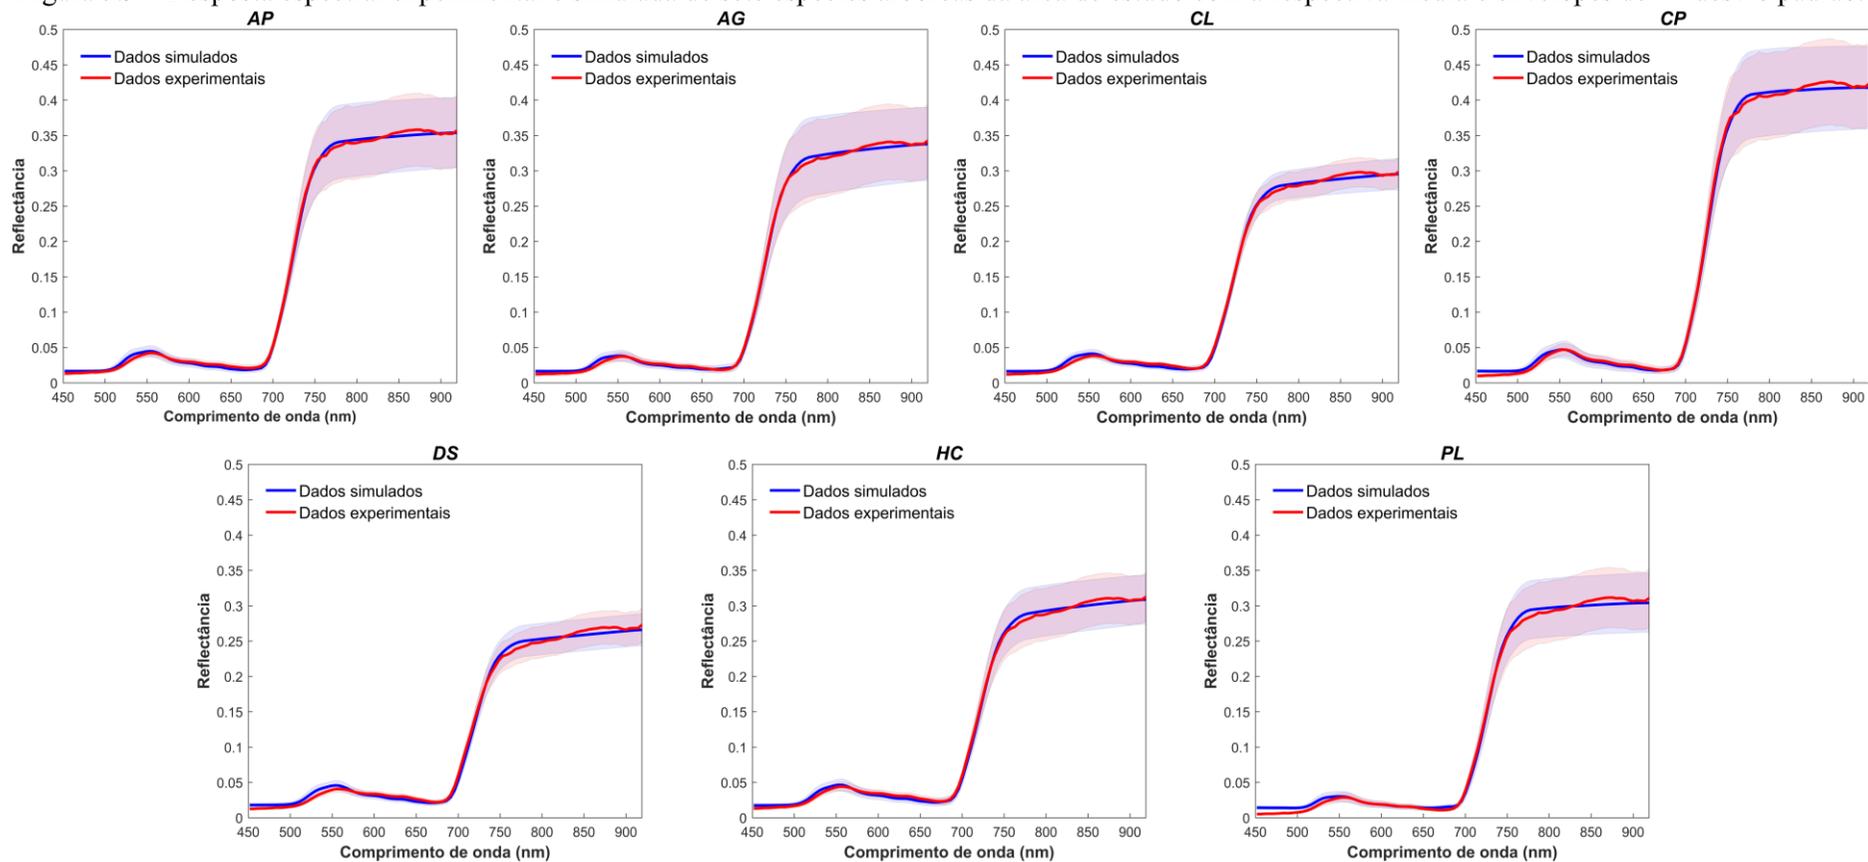
A resposta espectral média de cada espécie foi representada graficamente que questões de clareza. AP=Aspidosperma polyneuron; AG=Astronium graveolens; CL=Cariniana legalis; CP=Croton piptocalyx; DS=Diatenopteryx sorbifolia; HC=Hymenaea courbaril; PL=Pachystroma longifolium.

Fonte: Produção do autor.

redor de 865 nm, onde a reflectância experimental foi sutilmente mais alta do que a simulada, claramente visível na resposta espectral de *CP* e *PL* (Figura 5.9). A reflectância do dossel a 865 nm depende da feição de absorção de água localizada em torno de 1000 nm. A profundidade dessa feição é controlada principalmente pelo IAF (ASNER, 1998), pois a absorção de água aumenta de acordo com o incremento da biomassa. *PL* é uma espécie perene que geralmente forma aglomerações monoespecíficas de elevada biomassa foliar e responsável por condições de baixa luminosidade no solo da floresta (GANDOLFI et al., 2007). *CP* é uma árvore decídua e apresenta elevada variabilidade espectral (envelopes de desvio padrão na Figura 5.9), derivada de copas com diferentes graus de deciduidade e, conseqüentemente, menor biomassa foliar na copa. Outra região espectral com consideráveis valores de RMSD está localizada na extremidade da borda do vermelho a 775 nm. Tomando *PL* ou *DS* como exemplos, esse comprimento de onda representa o início do platô NIR que foi ligeiramente superestimado nos dados simulados (Figura 5.9).

As técnicas de inversão de modelos de transferência radiativa (Seção 2.3.2.1), utilizadas para extração de atributos da vegetação a partir de medições da reflectância, dependem primordialmente de uma boa concordância entre os dados reais e simulados. O modelo DART foi capaz de simular de forma acurada a resposta espectral das espécies, mas para atestar a qualidade de estimativas de parâmetros bioquímicos por inversão, é necessário um procedimento de validação, que pode ser realizado idelamente com a aquisição de dados hiperespectrais e de campo obtidos de forma concomitante. Neste trabalho, embora os dados de campo e as imagens hiperespectrais não tenham sido adquiridos na mesma data é possível utilizar índices de vegetação para averiguar a qualidade de inversões do modelo. Esses índices, particularmente os de bandas estreitas (Seção 4.1.1.1.1), foram desenvolvidos e testados para estimativa de vários atributos da vegetação. O modelo DART foi invertido para os *pixels* contidos no interior da copa das espécies arbóreas. O processo de inversão foi baseado na comparação entre espectros da LUT e a resposta espectral dos *pixels*. Para cada *pixel*, foram encontrados os 20 espectros simulados mais parecidos (menores valores de RMSD), em seguida a média dos parâmetros DART que geraram esses espectros

Figura 5.9 – Resposta espectral experimental e simulada de sete espécies arbóreas da área de estudo com a respectiva média e envelopes de  $\pm 1$  desvio padrão.

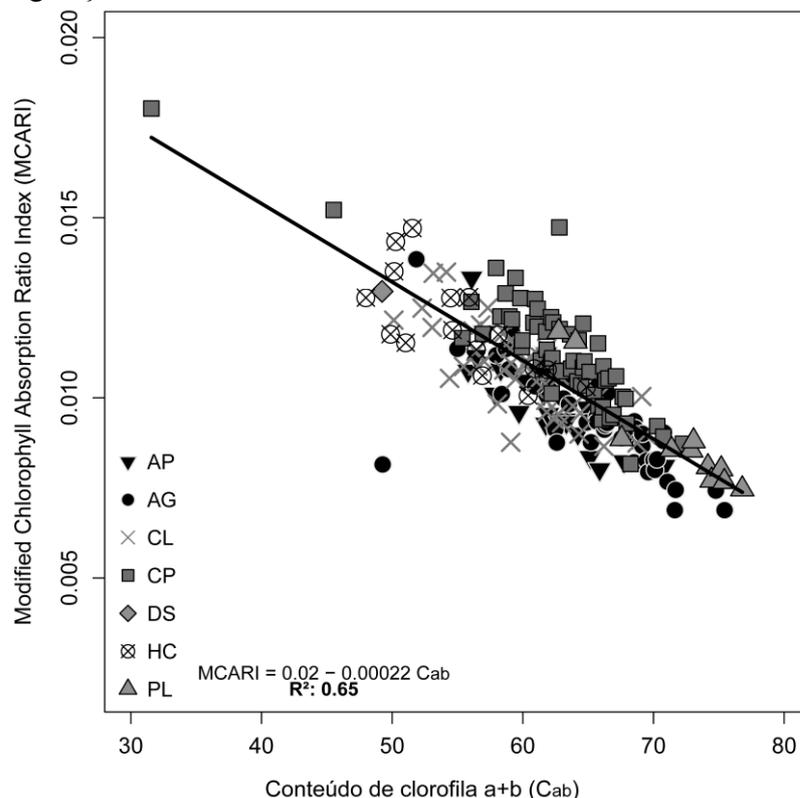


AP=*Aspidosperma polyneuron*; AG=*Astronium graveolens*; CL=*Cariniana legalis*; CP=*Croton piptocalyx*; DS= *Diatenopteryx sorbifolia*; HC=*Hymenaea courbaril*; PL= *Pachystroma longifolium*.

Fonte: Produção do autor.

foi computada e atribuída ao *pixel*. Após verificar a relação entre os IVs calculados com bandas do VNIR (Tabela 4.1) e os parâmetros do modelo, verificou-se que a melhor relação foi entre  $C_{ab}$  e MCARI, conforme apresentado na Figura 5.10. MCARI (*Modified Chlorophyll Absorption in Reflectance Index*) é uma modificação do CARI (*Chlorophyll Absorption in Reflectance Index*), concebido para minimizar os efeitos da refletância do solo e materiais não-fotossintéticos em estimativas de  $C_{ab}$ . Zarco-Tejada et al. (2004b) encontraram relações significativas entre a  $C_{ab}$  mensurada de folhas de *Olea europaea L.* e o MCARI calculado com *pixels* das copas ( $R^2=0,65$ ). Os autores obtiveram relações inversas entre MCARI e  $C_{ab}$  (refira-se à Figura 11 de Zarco-Tejada et al. (2004b)), cuja forma foi muito parecida à apresentada na Figura 5.10.

Figura 5.10 – Gráfico de dispersão entre o conteúdo de clorofila ( $C_{ab}$ ) e o índice de vegetação MCARI.

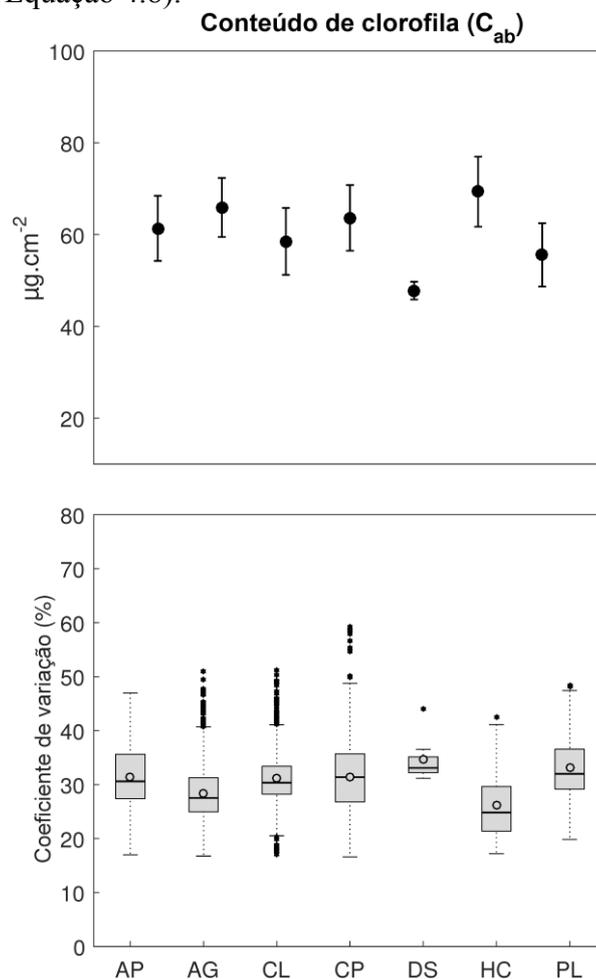


Cada ponto representa o conteúdo de clorofila ( $C_{ab}$ ) de uma copa das espécies arbóreas, obtido por inversão do modelo DART. O processo de inversão foi baseado na comparação entre espectros da LUT e a resposta espectral dos *pixels*. Para cada *pixel*, foram encontrados os 20 espectros simulados mais parecidos (menores valores de RMSD), a média dos parâmetros DART que geraram esses espectros foi computada e atribuída ao *pixel*. O índice de vegetação utilizado foi o MCARI (*Modified Chlorophyll Absorption Reflectance Index*) cuja equação é apresentada na Tabela 4.1.

Fonte: Produção do autor.

Os resultados da inversão do DART para cada espécie são apresentados na Figura 5.11. Após o cômputo da média e desvio padrão dos parâmetros que originaram os 20 espectros simulados mais parecidos com cada espectro medido, foi verificado que a distribuição de  $C_{ab}$  é relativamente alta entre as espécies (linha inferior da Figura 5.11). A variabilidade desse parâmetro foi quantificada pelo cálculo do coeficiente de variação (CV). Em termos médios, os CVs variam de 26.1% a 34.7% (média dos *boxplots* na linha inferior da Figura 5.11). A elevada variabilidade do CV da  $C_{ab}$  obtidas por inversão significa que, embora as simulações das respostas espectrais das espécies tenham sido acuradas, a inversão do DART para a estimativa de parâmetros biofísicos e bioquímicos ainda é um desafio. Entretanto, é interessante notar que as espécies apresentaram valores de  $C_{ab}$  estatisticamente diferentes entre si (valor-p do teste da soma de postos de Wilcoxon  $< 0.01$ ), ressaltando a utilidade desse parâmetro na discriminação das mesmas.

Figura 5.11 – Variabilidade do conteúdo de clorofila ( $C_{ab}$ ) que originou os 20 espectros simulados mais semelhantes a cada pixel das espécies arbóreas (menor RMSD, Equação 4.8).



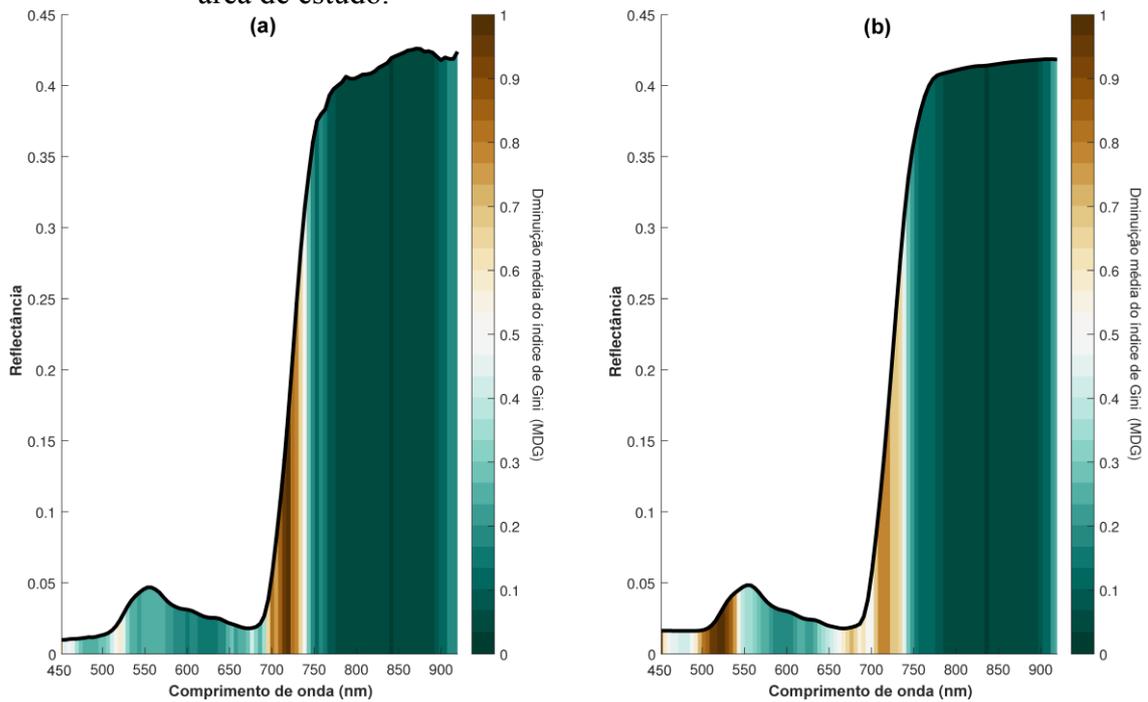
Linha superior: Média  $\pm$  1 desvio padrão do conteúdo de clorofila espécie arbórea obtido por inversão do modelo DART. Linha inferior: Boxplots mostrando a variabilidade dos coeficientes de variação. As linhas centrais são as medianas, e os pontos centrais das caixas são as médias. Os quartis superior e inferior são representados pelas arestas das caixas. A linha tracejada se estende até os pontos de dados mais extremos que não são considerados *outliers* (discrepantes). *Outliers* são representados individualmente. AP=*Aspidosperma polyneuron*; AG=*Astronium graveolens*; CL=*Cariniana legalis*; CP=*Croton piptocalyx*; DS= *Diatenopteryx sorbifolia*; HC=*Hymenaea courbaril*; PL= *Pachystroma longifolium*.

Fonte: Produção do autor.

### 5.2.2. Importância de atributos e separabilidade espectral

Indicadores de importância de atributos foram estimados para avaliar se regiões espectrais importantes para discriminar as espécies foram preservadas nas simulações. Isso foi confirmado pelo fato de que a diminuição média do índice de Gini (MDG) obtida com espectros simulados e experimentais apresentou padrões semelhantes entre si (Figura 5.12). Em ambos os conjuntos de dados, as bandas menos importantes foram encontradas no NIR e as mais importantes concentradas nas regiões espectrais localizadas entre 500-550 nm e 700-725 nm. O cálculo da MDG mostrou a relevância de bandas ao redor de 525 nm na discriminação das espécies, tanto em dados reais quanto simulados. Isso comprova que, embora o RMSD dessa região tenha sido relativamente alto (Figura 5.8), a discordância entre espectros medidos e simulados não foi capaz de descaracterizar feições importantes para classificar as espécies. Na realidade, os altos valores de MDG encontrados próximos a 525 nm e a 700 nm significam que, ao redor desses comprimentos de onda, a resposta espectral das espécies variou significativamente. Gitelson et al. (2002b) demonstraram que a feição de absorção em 520 nm está diretamente relacionada à concentração de carotenoides nas folhas ( $C_{xc}$ ). Mais recentemente, Zarco-Tejada et al. (2013) utilizaram dados hiperespectrais aerotransportados para estimar o conteúdo de carotenoide foliar em parreirais e descobriram que uma razão entre as bandas centradas em 515 e 570 nm é sensível à  $C_{xc}$ . Outros estudos utilizaram, também, a região ao redor de 700 nm para estimar  $C_{xc}$  (CHAPPELLE et al., 1992; MERZLYAK et al., 1999). Tais exemplos demonstram que a reflectância em 525 e 700 nm tem relação direta com a concentração de carotenoides. Na área de estudo, as árvores tendem a naturalmente perder suas folhas e, no processo de senescência, os carotenoides são retidos por mais tempo do que as clorofilas (BISWAL, 1995), explicando a importância dos referidos comprimentos de onda na diferenciação das espécies.

figura 5.12 – Importância de bandas do visível/infravermelho próximo estimadas pela diminuição média do índice de Gini (MDG) de sete espécies arbóreas da área de estudo.



(a) espectros experimentais e (b) suas contrapartes simuladas. MDG foi calculada 100 vezes com uma base de dados balanceada com a resposta espectral de sete árvores por espécie, as árvores mudaram a cada iteração. A resposta espectral média de *Croton piptocalyx* foi inserida em (a) e (b) para ajudar na visualização.

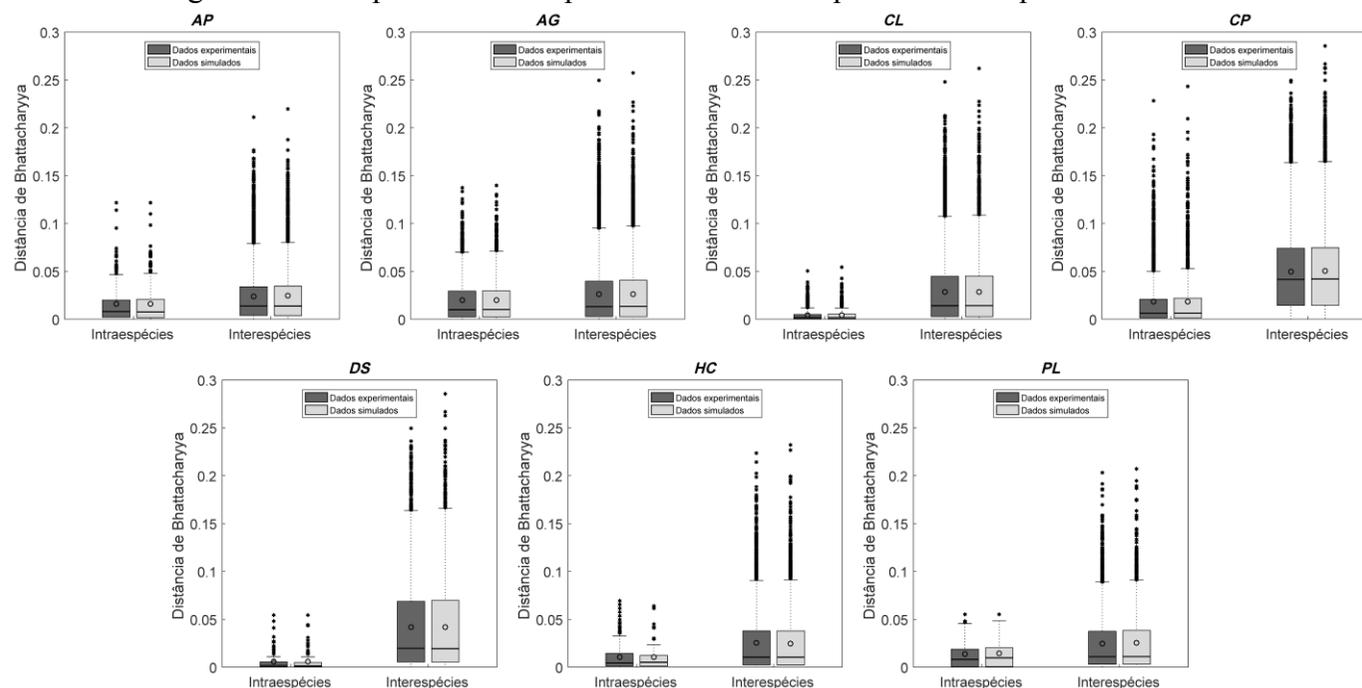
Fonte: Produção do autor.

Conforme apresentado na Seção 5.1.1 o desempenho de métodos estatísticos de classificação está relacionado à quantidade de diferença existente entre a variabilidade intra e interespecífica. A distância de Bhattacharyya (Equação 4.4) calculada intra e interespecíes com dados experimentais não diferiu estatisticamente daquela obtida com espectros simulados (valor-p do teste da soma de postos de Wilcoxon  $> 0.5$ ; Figura 5.13). Quaisquer que sejam os dados utilizados, a separabilidade intraespécies diferiu estatisticamente da separabilidade interespecíes (valor-p do teste da soma de postos de Wilcoxon  $< 0.001$ ). A distribuição da distância de Bhattacharyya é consistente com a variabilidade espectral intraespecífica das espécies. Por exemplo, *CL* e *DS* apresentaram as menores dispersões intraespécie (Figura 5.13), e suas respostas espectrais possuem os menores envelopes de desvio padrão (Figura 5.4), ou seja, menor variação.

### 5.2.3. Análise de sensibilidade

Com a análise de sensibilidade foi possível conhecer a influência de cada parâmetro DART na reflectância simulada do topo do dossel (Figura 5.14) e, assim, entender quais foram as variáveis que mais contribuíram para as discordâncias observadas entre os espectros simulados e reais. A região do VIS foi afetada mais intensamente pelas propriedades ópticas das folhas do que pelos parâmetros estruturais da copa. Notadamente, as variações na  $C_{ab}$  alteraram o espectro entre o pico do verde (550 nm) e a borda do vermelho (700-750 nm). De forma mais sutil,  $C_{xc}$  e  $N$  também afetaram o VIS, enquanto  $N$  impactou toda região ocasionando o incremento da amplitude do espectro,  $C_{xc}$  produziu variações apenas ao redor de 525 nm.  $C_m$  e  $C_w$  produziram variações desprezíveis no VIS, com este não levando a qualquer alteração e, aquele afetando intensamente apenas o NIR. Uma visão mais detalhada da influência de cada parâmetro ao longo do intervalo espectral considerado é fornecida na Figura 5.15, que mostra a dinâmica dos índices de sensibilidade. Para a maioria dos parâmetros, os padrões de alteração nos valores de reflectância mostrados na Figura 5.14 são confirmados. Por exemplo, variações produzidas ao redor de 525 nm por  $C_{xc}$  também são observados na Figura 5.15. O mesmo se aplica para  $C_{ab}$ ,  $N$ ,  $C_m$ ,  $C_w$ , LAD, DLF, DBF, OBF e OGF. Entretanto, o cálculo dos índices de sensibilidade revelou uma influência significativa de pCells na variabilidade da reflectância do dossel de 450 a 539 nm, o que não pode ser claramente verificado na Figura 5.14.

Figura 5.13 – Separabilidade espectral intra e interespecífica das espécies arbóreas.



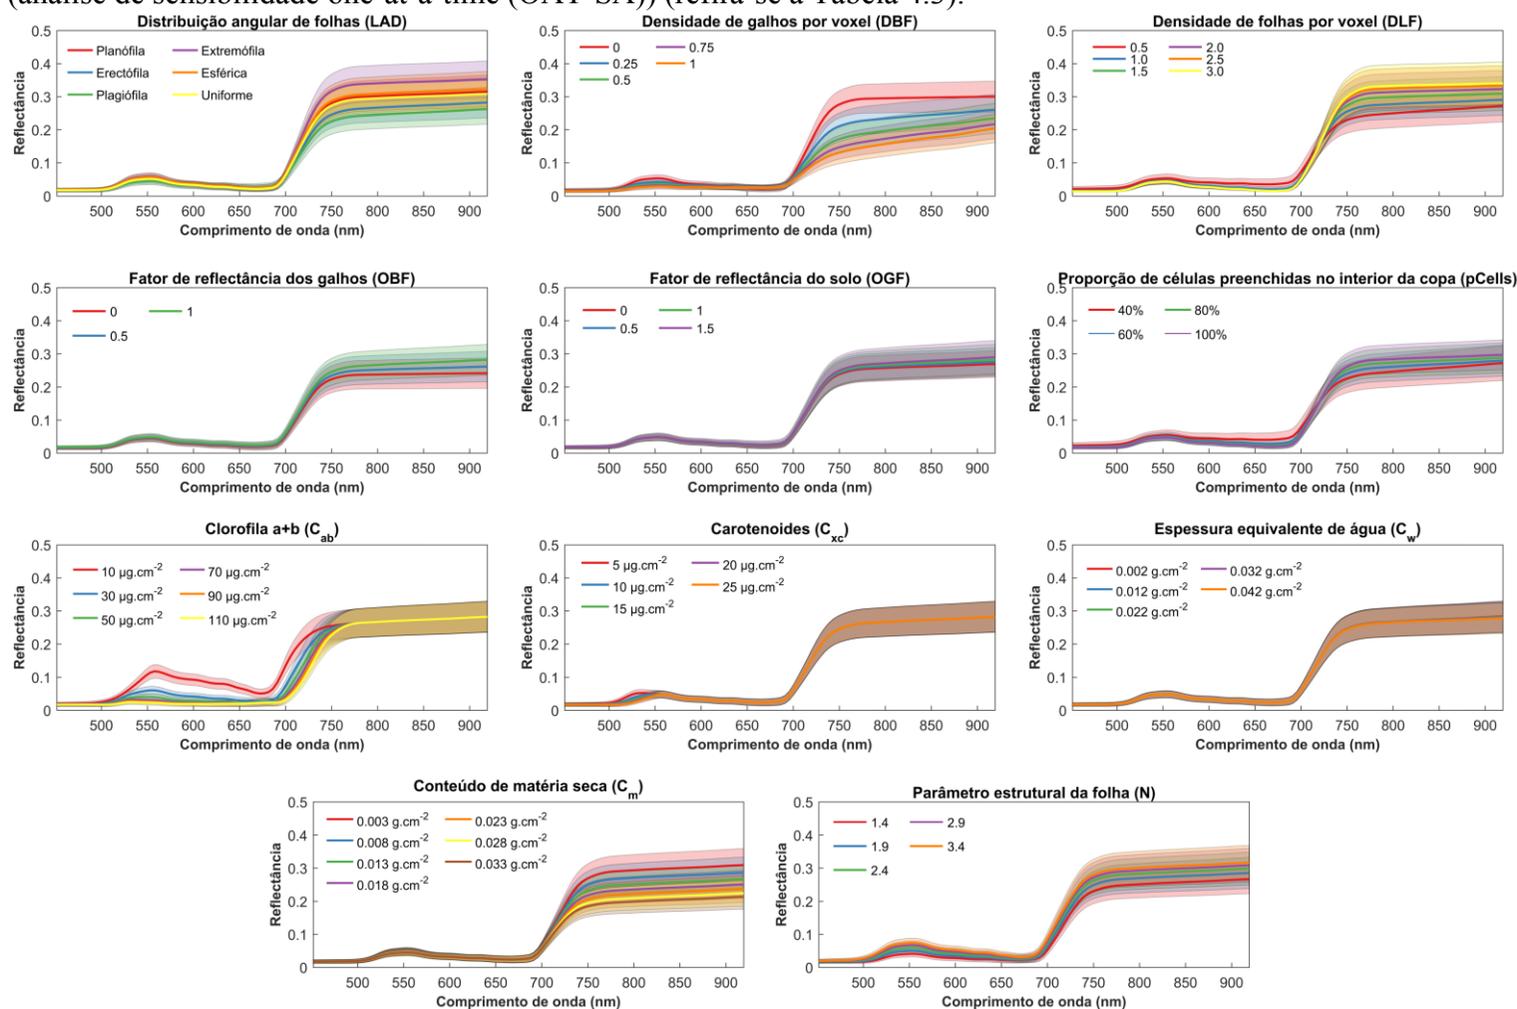
Boxplots (a) - (d) que mostram a distância de Bhattacharyya (Equação 4.4) calculada intra e interespecíes para a resposta espectral experimental e simulada de sete espécies arbóreas da área de estudo. As linhas centrais são as medianas e os pontos centrais das caixas são as médias. Os quartis superior e inferior são representados pelas arestas das caixas. A linha tracejada se estende até os pontos de dados mais extremos que não são considerados *outliers* (discrepantes). *Outliers* são representados individualmente. O valor-p do teste da soma de postos de Wilcoxon obtido após comparar as distâncias de Bhattacharyya calculadas com dados experimentais e simulados é mostrado. AP=*Aspidosperma polyneuron*; AG=*Astronium graveolens*; CL=*Cariniana legalis*; CP=*Croton piptocalyx*; DS= *Diatenopteryx sorbifolia*; HC=*Hymenaea courbaril*; PL=*Pachystroma longifolium*.

Fonte: Produção do autor.

Como salientado anteriormente, as discordâncias mais proeminentes foram observadas na região do NIR, particularmente em 775 e 865 nm. Embora essas diferenças tenham sido insignificantes, já que não influenciaram o poder discriminante das bandas hiperespectrais (Figura 5.12) tampouco a separabilidade espectral das espécies (Figura 5.13), a OAT-SA proporcionou um melhor entendimento dos parâmetros do modelo que influenciaram a reflectância simulada no NIR. Dos parâmetros que controlam as propriedades ópticas das folhas, é interessante notar que a reflectância do dossel é sensível a variações de  $N$  e  $C_m$  (Figura 5.13; Figura 5.14), o que corrobora os resultados de Ceccato et al. (2001). De acordo com Jacquemoud et al. (2009), grande parte da contribuição de  $C_m$  para reflectância do dossel advém do NIR e essa contribuição aumenta em condições de LAI elevado. Xiao et al. (2014) mostraram que a variação de  $C_m$  tem uma importância maior para a reflectância do dossel do que da folha.

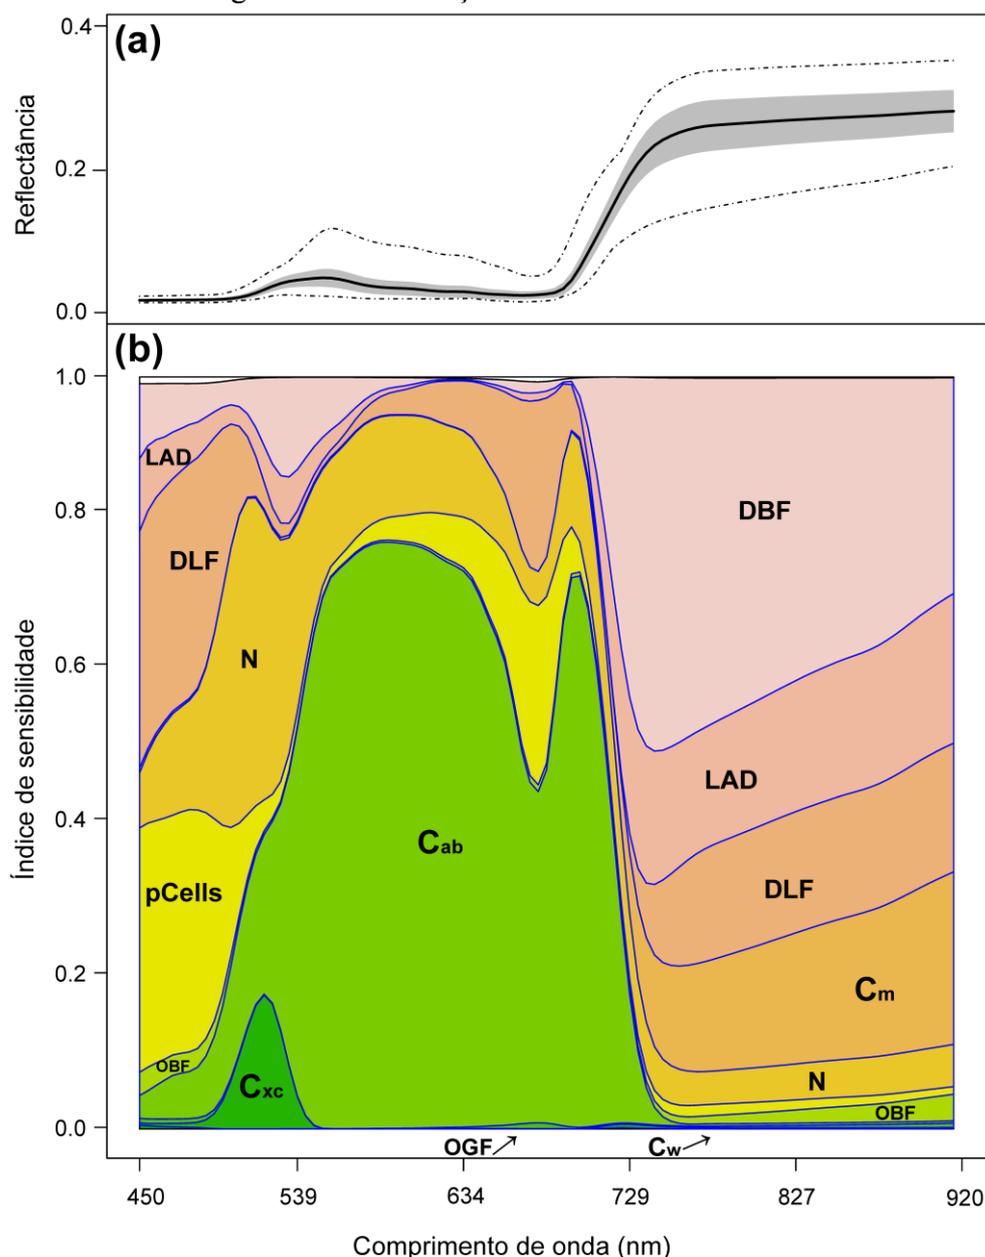
Vários parâmetros estruturais do dossel (Tabela 4.3) produziram variações no domínio do NIR (Figuras 5.14, Figura 5.15). De forma mais acentuada, a densidade de galhos por *voxel* (DBF) eleva a reflectância quando seu valor decresce, padrão este, observado por Asner (1998) que estudou os efeitos de elementos lenhosos na resposta espectral de dosséis. Malenovsky et al. (2008) investigaram a influência de elementos lenhosos na reflectância simulada do dossel pelo DART e descobriram que a alta absorção da luz por esses elementos diminui a reflectância no NIR. Em menor grau, o fator de reflectância dos galhos (OBF) também afetou a resposta radiométrica do dossel no NIR (Figura 5.14). OBF é diretamente proporcional à reflectância, o que é explicado pelo aumento de fótons sofrendo espalhamento múltiplo no interior da copa em condições de elevado OBF. A reflectância no NIR também foi afetada pela LAD e pela densidade de folhas por *voxel* (DLF) (Figura 5.14, Figura 5.15). No DART, DLF está diretamente relacionado ao índice de área da planta (PAI) da árvore. Estudos anteriores mostraram que LAD e IAF são os parâmetros dominantes que controlam a reflectância do dossel (ASNER, 1998). Xiao et al. (2014) demonstraram que a importância das propriedades ópticas foliares ( $C_{ab}$ ,  $C_m$ ,  $C_w$  e  $N$ ) está fortemente relacionada ao IAF. Outro parâmetro que afetou a reflectância no NIR foi a proporção de células preenchidas no interior da copa (pCells).

Figura 5.14 – Variação da resposta espectral das simulações DART após a variação de um parâmetro por vez e mantendo os outros constantes (análise de sensibilidade one-at-a-time (OAT-SA)) (refira-se à Tabela 4.3).



Fonte: Produção do autor.

Figura 5.15 – Variação dos índices de sensibilidade.



(a) Extremos (linhas pontilhadas), intervalo interquartil (cinza) e média (linha em negro) dos valores de reflectância simulados pelo modelo DART, obtidos após variar um parâmetro por vez, mantendo os outros constantes (análise de sensibilidade *one-at-a-time* (OAT-SA)) (refira-se à Tabela 4.3). (b) dinâmica dos índices de sensibilidade para a OAT-SA ao longo do intervalo espectral de 450 a 920 nm. **LAD** = Distribuição angular de folhas; **DBF** = Densidade de galhos por *voxel*; **DLF** = Densidade de folhas por *voxel*; **pCells** = Proporção de células preenchidas no interior da copa; **OBF** = Fator de reflectância dos galhos; **OGF** = Fator de reflectância do solo; **C<sub>ab</sub>** = Clorofila *a+b*; **C<sub>xc</sub>** = Carotenoides; **C<sub>w</sub>** = Espessura equivalente de água; **C<sub>m</sub>** = Conteúdo de matéria seca; **N** = Parâmetro estrutural da folha.

Fonte: Produção do autor.

Quando pCells atingiu um valor de 100%, que significa a ausência de células vazias no interior da copa, a reflectância aumentou. Isso é esperado, já que um número maior de células preenchidas com folhas e material lenhoso aumenta o espalhamento múltiplo e favorece a quantidade de radiação que deixa o dossel.

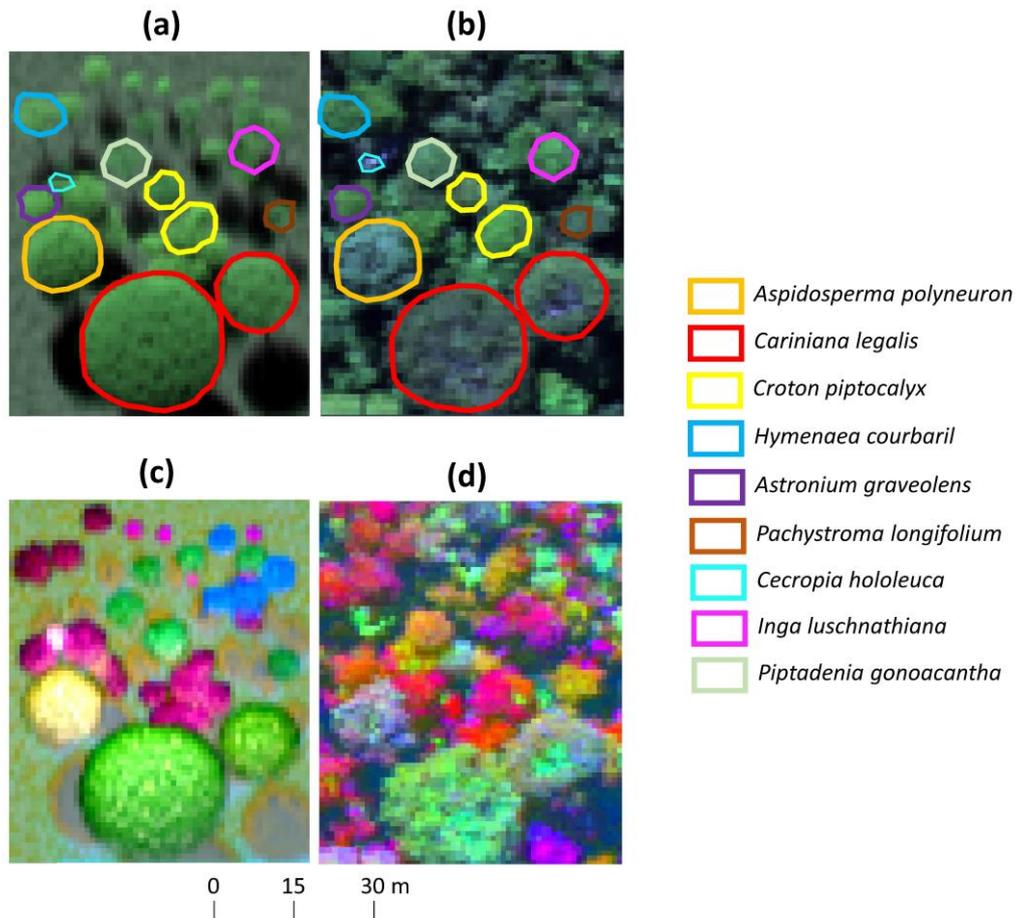
Os parâmetros estruturais do dossel (Tabela 4.3) foram responsáveis pela maior parte da variação da reflectância simulada no NIR. A simulação da estrutura do dossel de florestas tropicais ainda é um desafio, mesmo com a utilização de modelos de transferência radiativa que operam em 3D. Recentemente, Morton et al. (2016) empregaram dados LiDAR aerotransportados de alta densidade para desenvolver uma representação em 3D de uma floresta amazônica com o modelo DART. Os dados LiDAR permitiram aos autores construir uma representação realística da floresta para simular de forma acurada a variabilidade diurna e sazonal da utilização de luz. A tecnologia de LiDAR terrestre também pode ser utilizada para representar a arquitetura das árvores e extrair atributos estruturais do dossel (CÔTE et al., 2011). Esses exemplos mostram que dados LiDAR são capazes de fornecer informações valiosas sobre a estrutura do dossel. Entretanto, sua aquisição envolve altos custos, principalmente em áreas remotas de floresta tropical. Neste trabalho, foi demonstrado que a resposta espectral de espécies arbóreas pode ser acuradamente simulada por meio de uma representação simples da estrutura da copa.

#### **5.2.4. Simulação de imagens hiperespectrais**

O modelo DART foi utilizado em pesquisas anteriores para descrever florestas tropicais (GASTELLU-ETCHEGORRY et al., 1996; BARBIER et al., 2010; MORTON et al., 2016), mas este trabalho foi o primeiro a demonstrar sua utilidade para simular a resposta espectral de espécies arbóreas tropicais ao nível de dossel. A abordagem desenvolvida se mostrou eficaz na simulação da reflectância de ITCs. Entretanto, buscou-se também explorar a peculiaridade do modelo DART em simular imagens hiperespectrais da área de estudo e compará-las com imagens reais obtidas pelo sensor ProSpecTIR-VS. A comparação entre imagens reais e simuladas não foi realizada ao nível de *pixel*, visto que os dados de campo utilizados nas simulações e as imagens hiperespectrais não foram adquiridos de forma concomitante. O objetivo foi obter uma representação virtual

da parcela experimental que se assemelhasse à realidade. Para tanto, foram coletados diversos dados acerca das árvores que dominavam o dossel (refira-se à Seção 3.5 para maiores detalhes). A Figura 5.16 apresenta uma comparação visual da imagem da parcela experimental adquirida pelo sensor ProSpecTIR-VS e sua contraparte simulada pelo modelo DART.

Figura 5.16 – Comparação entre imagens hiperespectrais reais e simuladas pelo modelo DART.



(a) Composição colorida em cor verdadeira (R=639 nm, G=548 nm, B=460 nm) da imagem hiperespectral simulada pelo modelo DART. (b) Composição colorida (R=639 nm, G=548 nm, B=460 nm) da imagem hiperespectral adquirida pelo sensor aerotransportado ProSpecTIR-VS da mesma área. (c) Transformação por principais componentes da imagem simulada pelo DART (R=PC7, B=PC6, G=PC5). (d) Transformação por principais componentes da imagem hiperespectral real (R=PC3, B=PC2, G=PC1). A imagem DART foi simulada a partir de dados acerca das árvores que dominavam o dossel de uma parcela experimental com raio de 30 metros (refira-se à Seção 3.5). Espécies arbóreas do interior da parcela são representadas por diferentes cores em (a) e (b). Por questões de clareza, apenas nove espécies são mostradas, das quais seis foram simuladas neste estudo (Tabela 3.4).

Fonte: Produção do autor.

A aplicação da transformação por principais componentes (JIA; RICHARDS, 1999) em ambas as bases de dados revelou diferenças na resposta espectral das espécies (Figura 5.15c e Figura 5.15d). A Figura 5.15 mostra que o modelo DART é capaz de lidar com a estrutura (dimensões da copa) e diversidade espectral existente em florestas tropicais. A utilização do modelo para extração de atributos químicos das espécies necessita ser validada com dados espectrais de campo e aéreos que tenham sido adquiridos simultaneamente. No entanto, essa ferramenta de modelagem pode ser utilizada futuramente em pesquisas que explorem dados hiperspectrais para estudar florestas tropicais. Por exemplo, métodos de mapeamento da diversidade de espécies podem ser desenvolvidos e aprimorados pela simulação de diversas condições de aquisição da imagem, efeitos atmosféricos e composição de espécies.

## 6 CONCLUSÕES

Este trabalho foi o primeiro a demonstrar a potencialidade de imagens hiperespectrais de alta resolução espacial para a discriminação e mapeamento de espécies arbóreas da Floresta Atlântica, em particular espécies da Floresta Estacional Semidecidual. Além disso, foi comprovado que a resposta espectral dessas espécies ao nível de dossel é acuradamente simulada por modelagem de transferência radiativa em 3D. Com base nos resultados obtidos nesta pesquisa, foi possível traçar as seguintes conclusões:

- a) Dos métodos estatísticos de classificação aqui testados, a LDA atingiu os melhores resultados ao nível de *pixel*, com uma exatidão média de 84% ao se utilizar 260 bandas espectrais no intervalo VSWIR. O procedimento de seleção de bandas não influenciou significativamente os resultados da classificação, mas foi útil na identificação de regiões e bandas espectrais propícias à discriminação das espécies;
- b) No VNIR as bandas espectrais que mais contribuíram para a classificação das espécies estão localizadas no pico do verde (550 nm) e na feição de absorção no vermelho (650 nm). No SWIR elas se encontram ao redor de 1200 nm, 1700 nm, 2100 nm e 2300 nm. A incorporação de bandas do SWIR no processo de classificação elevou a exatidão de todos os métodos testados. Isso também foi verificado ao se utilizar dados reais e simulados do sensor WV-3;
- c) IVs de bandas estreitas contribuíram significativamente para discriminação das espécies apenas quando foram incorporados às bandas VNIR no processo de classificação;
- d) A exatidão de classificação de todos os métodos testados está diretamente relacionada à diferença existente entre a variabilidade intra e interespecífica de cada espécie. Após repetir o procedimento de classificação por 100 vezes, utilizando-se, a cada vez, ITCs de treinamento e teste diferentes, foi constatado que a variabilidade da exatidão de discriminação de uma determinada espécie é proporcional à sua variabilidade intraespecífica;

- e) A abordagem de classificação orientada a objetos desenvolvida foi capaz de gerar mapas de espécies acurados e fidedignos. O caráter inovador dessa abordagem reside na utilização de um limiar de probabilidade para rotular apenas *pixels* representativos das espécies alvo em conjunto com o delineamento automático de copas. O emprego da distância de Jeffreys-Matusita (Equação 4.3) se mostrou eficaz na união de segmentos vizinhos espectralmente semelhantes que pertenciam a uma mesma copa, elevando significativamente a exatidão dos mapeamentos. Vale destacar que o método RBF-SVM produziu o melhor resultado para o mapeamento da distribuição espacial das espécies arbóreas da área de estudo, detectando em média 84,9% dos ITCs.
- f) A abordagem de modelagem de transferência radiativa em 3D desenvolvida com o modelo DART, que representou a copa das árvores por uma estrutura simples composta por *voxels* contendo as propriedades ópticas de folhas e galhos, mostrou-se capaz de simular a resposta espectral das espécies arbóreas ao nível de dossel de forma acurada.
- g) A diferença entre a resposta espectral obtida pelo sensor ProSpecTIR-VS e a simulada pelo modelo DART não ultrapassou 1.8% de RMSD. As simulações preservaram importantes feições, observadas em dados reais, úteis para discriminar as espécies. A separabilidade espectral intra e interespecífica entre dados reais e simulados não apresentou diferença estatística significativa.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ALLEN, W. A.; GAUSMAN, H. W.; RICHARDSON, A. J.; THOMAS, J. R. Interaction of isotropic light with a compact plant leaf. **Journal of the Optical Society of America**. v.59, n.10, p.1376-1381, 1969.
- ALLEN, W. A.; GAYLE, T. V.; RICHARDSON, A. J. Plant-canopy irradiance specified by the Duntley equations. **Journal of the Optical Society of America**, v.60, p.372-376, 1970.
- ALLEN, W. A.; RICHARDSON, A. J. Interaction of light with a plant canopy. **Journal of the Optical Society of America**, v.58, n.8, p.1023-1028, 1968.
- AMARAL, C. H.; ROBERTS, D. A.; ALMEIDA, T. I. ; SOUZA FILHO, C. R. Mapping invasive species and spectral mixture relationships with neotropical woody formations in southeastern Brazil. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 108, p. 80-93, 2015.
- ANALYTICAL SPECTRAL DEVICES (ASD). **Leaf clip product sheet**. Boulder, CO : ASD Inc., 2011. Disponível em:<<http://www.asdi.com/products/accessories/contact-sampling-accessories/leaf-clip>>. Acesso em: 28 fev. 2013).
- ASNER, G. P. Biophysical and biochemical sources of variability in canopy reflectance. **Remote sensing of Environment**, v. 64, n. 3, p. 234-253, 1998.
- ASNER, G.P.; NEPSTAD, D.; CARDINOT, G.; RAY, D. Drought stress and carbon uptake in an Amazon forest measured with spaceborne imaging spectroscopy. **Proceedings of the National Academy of Sciences of the United States of America**, v. 101, n. 16, p. 6039-6044, 2004.
- ASNER, G.P.; VITOUSEK, P.M. Remote analysis of biological invasion and biogeochemical change. **Proceedings of the National Academy of Sciences**, v. 102, n. 12, p. 4383–4386, 2005.
- ASNER, G. P.; MARTIN, R. E.; CARRANZA-JIMÉNEZ, L.; SINCA, F.; TUPAYACHI, R.; ANDERSON, C. B.; MARTINEZ, P. Functional and biological diversity of foliar spectra in tree canopies throughout the Andes to Amazon region. **New Phytologist**, v. 204, n. 1, p. 127-139, 2014.
- BALDECK, C. A.; ASNER, G.P. Improving remote species identification through efficient training data collection. **Remote Sensing**, v. 6, n. 4, p. 2682-2698, 2014.
- BALDECK, C. A.; ASNER, G.P.; MARTIN, R. E.; ANDERSON, C. B.; KNAPP, D. E.; KELLNER, J. R.; WRIGHT, S. J. Operational tree species mapping in a diverse tropical forest with airborne imaging spectroscopy. **PloS one**, v. 10, n. 7, p. e0118403, 2015.

BANDOS, T.V.; BRUZZONE, L.; CAMPS-VALLS, G. Classification of hyperspectral images with regularized linear discriminant analysis. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 3, p. 862-873, 2009.

BARBIER, N.; COUTERON, P.; PROISY, C.; MALHI, Y.; GASTELLU-ETCHEGORRY, J. P. The variation of apparent crown size and canopy heterogeneity across lowland Amazonian forests. **Global Ecology and Biogeography**, v. 19, n. 1, p. 72-84, 2010.

BARRY, K. M.; NEWNHAM, G. J.; STONE, C. Estimation of chlorophyll content in Eucalyptus globulus foliage with the leaf reflectance model PROSPECT. **Agricultural and forest meteorology**, v. 149, n. 6, p. 1209-1213, 2009.

BISWAL, B. Carotenoid catabolism during leaf senescence and its control by light. **Journal of Photochemistry and Photobiology B: Biology**, v. 30, n. 1, p. 3-13, 1995.

BLACKBURN, G.A. Quantifying chlorophylls and carotenoids from leaf to canopy scale: an evaluation of some hyperspectral approaches. **Remote sensing of environment**, v. 66, n. 3, p. 273-285, 1998.

Boardman, J.W., 1993. Automating spectral unmixing of AVIRIS data using convex geometry concepts. In: JPL AIRBORNE GEOSCIENCE WORKSHOP., 1993. Pasadena. **Proceedings...** 1993. p. 11-14.

BREIMAN, L. Random forests. **Machine learning**, v. 45, n. 1, p. 5-32, 2001.

BREIMAN, L.; CUTLER, A. **Random forests**. 2004. Disponível em: <[http://statwww.berkeley.edu/users/breiman/RandomForests/cc\\_home.htm](http://statwww.berkeley.edu/users/breiman/RandomForests/cc_home.htm)>. Acesso em: 10 mar. 2015.

BRUCE, L.M.; MORGAN, C.; LARSEN, S. Automated detection of subpixel hyperspectral targets with continuous and discrete wavelet transforms. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n. 10, p. 2217-2226, 2001.

CALLE, M. L.; URREA, V. Letter to the editor: stability of random forest importance measures. **Briefings in bioinformatics**, v. 12, n. 1, p. 86-89, 2011.

CÂMARA, G.; SOUZA, R. C. M.; FREITAS, U. M.; GARRIDO, J. SPRING: Integrating remote sensing and GIS by object-oriented data modeling, **Computers & Graphics**, v. 20, n. 3, pp. 395-403, 1996.

CAMPOS, R. C. **Modelo de transferência radiativa para dosséis descontínuos regulares (GRART): aplicação para dosséis de café**. 2009. 154 p. (INPE-15678-TDI/1452). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2008. Disponível em: <<http://urlib.net/8JMKD3MGP8W/34MSUL8>>.

CASTRO-ESAU, K. L.; SÁNCHEZ-AZOFEIFA, G. A.; RIVARD, B.; WRIGHT, S. J.; QUESADA, M. Variability in leaf optical properties of Mesoamerican trees

- and the potential for species classification. **American Journal of Botany**, v. 93, n. 4, p. 517-530, 2006.
- CECCATO, P.; FLASSE, S.; TARANTOLA, S.; JACQUEMOUD, S.; GRÉGOIRE, J. M. Detecting vegetation leaf water content using reflectance in the optical domain. **Remote sensing of environment**, v. 77, n. 1, p. 22-33, 2001.
- CHAN, J. C. W.; PAELINCKX, D. Evaluation of Random Forest and Adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. **Remote Sensing of Environment**, v. 112, n. 6, p. 2999-3011, 2008.
- CHANG, C.C.; LIN, C.J. LIBSVM: A library for support vector machines. **ACM Transactions on Intelligent Systems and Technology (TIST)**, v. 2, n. 3, p. 27, 2011.
- CHAPPELLE, E.W.; KIM, M.S.; MCMURTREY, J.E.I. Ratio analysis of reflectance spectra (RARS): an algorithm for the remote estimation of the concentrations of chlorophyll a, chlorophyll b, and carotenoids in soybean leaves. **Remote Sensing of Environment**, v. 39, n. 3, p. 239-247, 1992.
- CHAPPELLE, O. ; VAPNIK, V.; BOUSQUET, O.; MUKHERJEE, S. Choosing multiple parameters for support vector machines. **Machine learning**, v. 46, n. 1-3, p. 131-159, 2002.
- CHARLES-EDWARDS, D. A.; THORNLEY, J. H. M. Light interception by an isolated plant: simple model. **Annals of Botany**, v.37, p.919-928, 1973.
- CHEN, C.; LIAW, A.; BREIMAN, L. **Using random forest to learn imbalanced data**. Berkeley: University of California, 2004. v. 110.
- CHERKASSKY, V.; MULIER, F.M. **Learning from data: concepts, theory, and methods**. 2. ed. New Jersey: John Wiley & Sons, 2007. 537 p.
- CHO, M. A.; MALAHLELA, O.; RAMOELO, A. Assessing the utility WorldView-2 imagery for tree species mapping in South African subtropical humid forest and the conservation implications: dukuduku forest patch as case study. **International Journal of Applied Earth Observation and Geoinformation**, v. 38, p. 349-357, 2015.
- CLARK, M. L.; ROBERTS, D. A.; CLARK, D. A. Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scales. **Remote Sensing of Environment**, v. 96, n. 3-4, p. 375-398, 2005.
- CLARK, M. L.; ROBERTS, D. A.; CLARK, D. A. Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scales. **Remote Sensing of Environment**, v. 96, n. 3-4, p. 375-398, 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.

- COLEMAN, T. F.; Y. LI. An interior, trust region approach for nonlinear minimization subject to bounds. **SIAM Journal on optimization**, v. 6, n. 2, p. 418-445, 1996.
- COMBAL, B.; BARET, F.; WEISS, M.; TRUBUIL, A.; MACÉ, D.; PRAGNÈRE, A.; MYENI, R.; KNYAZIKHIN, Y.; WANG, L. Retrieval of canopy biophysical variables from bidirectional reflectance: Using prior information to solve the ill-posed inverse problem. **Remote sensing of environment**, v. 84, n. 1, p. 1-15, 2003.
- CÔTÉ, J. F.; FOURNIER, R. A.; EGLI, R. An architectural model of trees to estimate forest structural attributes using terrestrial LiDAR. **Environmental Modelling & Software**, v. 26, n. 6, p. 761-777, 2011.
- COUTERON, P. Quantifying change in patterned semi-arid vegetation by Fourier analysis of digitized aerial photographs. **International Journal of Remote Sensing**, v. 23, n. 17, p. 3407-3425, 2002.
- DALPONTE, M.; BRUZZONE, L.; VESCOVO, L.; GIANELLE, D. The role of spectral resolution and classifier complexity in the analysis of hyperspectral images of forest areas. **Remote Sensing of Environment**, v. 113, n. 11, p. 2345-2355, 2009.
- DALPONTE, M.; ORKA, H. O.; GOBAKKEN, T.; GIANELLE, D.; NÆSSET, E. Tree species classification in boreal forests with hyperspectral data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 51, n. 5, p. 2632-2645, 2013.
- DISCRETE ANISOTROPIC RADIATIVE TRANSFER (DART). **User's manual**. Toulouse, France: Centre d'Etudes Spatiales de la Biosphère (CESBIO), 2014.
- DAUGHTRY, C.S.T.; WALTHALL, C.L.; KIM, M.S.; DE COLSTOUN, E.B.; MCMURTREY, J.E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote Sensing of Environment**, v. 74, n. 2, p. 229-239, 2000.
- DÍAZ, S.; CABIDO, M. Vive la difference: plant functional diversity matters to ecosystem processes. **Trends in ecology & evolution**, v. 16, n. 11, p. 646-655, 2001.
- DIAZ-URIARTE, R. GeneSrF and varSelRF: a web-based tool and R package for gene selection and classification using random forest. **BMC bioinformatics**, v. 8, n. 1, p. 328, 2007.
- Digital Globe (2013). DigitalGlobe Core Imagery Products Guide. Disponível em: < <http://www.geosoluciones.cl/documentos/worldview/DigitalGlobe-Core-Imagery-Products-Guide.pdf> >. Acesso em: 12 fev. 2017.

DISNEY, M. I.; LEWIS, P.; NORTH, P. R. J. Monte Carlo ray tracing in optical canopy reflectance modelling. **Remote Sensing Reviews**, v. 18, n. 2-4, p. 163-196, 2000.

DRAPER, N.R.; SMITH, H. **Applied regression analysis**. New York: Wiley, 2014.

DUDA, R.O.; HART, P.E.; STORK, D.H. **Pattern Classification**, 2. ed. New York: Wiley Interscience, 2001. 653 p.

EHLERS, M. Multi-image fusion in remote sensing: spatial enhancement vs spectral characteristics preservation. In: BEBIS, G.R.; BOYLE, B.; PARVIN, D.; KORACIN, P.; REMAGNINO, F.; PORIKLI, J.; PETERS, J.; KLOSOWSKI, L.; ARNS, Y.; CHUNRHYN, T.-M.; MONROE, L. (Eds.). **Advances in visual computing**. Berlin: Springer, 2008. p. 75–84.

ELVIDGE, C.D. Visible and near infrared reflectance characteristics of dry plant materials. **Remote Sensing**, v. 11, n. 10, p. 1775-1795, 1990.

FARAH, F.T.; RODRIGUES, R.R.; SANTOS, F.A.M.; TAMASHIRO, J.Y.; SHEPHERD, G.J.; SIQUEIRA, T.; BATISTA, J.L.F.; MANLY, B.J.F. Forest destructuring as revealed by the temporal dynamics of fundamental species—Case study of Santa Genebra Forest in Brazil. **Ecological Indicators**, v. 37, p. 40-44, 2014.

FASSNACHT, F.; NEUMANN, C.; FORSTER, M.; BUDDENBAUM, H.; GHOSH, A.; CLASEN, A.; JOSHI, P.K.; KOCH, B. Comparison of feature reduction algorithms for classifying tree species with hyperspectral data on three central European test sites. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 6, p. 2547-2561, 2014.

FELDE, G.W.; ANDERSON, G.P.; ADLER-GOLDEN, S.M.; MATTHEW, N.W.; BERK, A., 2003. Analysis of hyperion data with the FLAASH atmospheric correction algorithm. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, (IGARSS), 2003, Toulouse. **Proceedings...** IEEE, 2003. p. 90-92. Disponível em: <<http://ieeexplore.ieee.org/Xplore/home.jsp>>. Acesso em: 08 mar. 2015.

FERET, J. ; ASNER, G.P. Semi-supervised methods to identify individual crowns of lowland tropical canopy species using imaging spectroscopy and LiDAR. **Remote Sensing**, v. 4, n. 8, p. 2457-2476, 2012.

FÉRET, J.B.; ASNER, G. P. Tree species discrimination in tropical forests using airborne imaging spectroscopy. **IEEE Transactions on Geoscience and Remote Sensing**, v. 51, n. 1, p. 73–84, 2013.

FÉRET, J.B.; ASNER, G.P. Spectroscopic classification of tropical forest species using radiative transfer modeling. **Remote Sensing of Environment**, v. 115, n. 9, p. 2415-422, 2011.

FÉRET, J.B.; FRANÇOIS, C.; ASNER, G.P.; GITELSON, A.A.; MARTIN, R.E.; BIDEL, L.P.R.; USTIN, S.L.; LE MAIRE, G.; JACQUEMOUD, S. PROSPECT-4 and 5: advances in the leaf optical properties model separating photosynthetic pigments. **Remote Sensing of Environment**, v. 112, n. 6, p. 3030-3043, 2008.

FERREIRA, M. P.; GRONDONA, A. E. B.; ROLIM, S. B.; SHIMABUKURO, Y. E. Analyzing the spectral variability of tropical tree species using hyperspectral feature selection and leaf optical modeling. **Journal of Applied Remote Sensing**, v. 7, 073502-1-073502-13, 2013.

FISHER, R. A. The use of multiple measurements in taxonomic problems. **Annals of eugenics**, v. 7, n. 2, p. 179-188, 1936.

FUENTES, D. A.; GAMON, J. A.; QIU, H. L.; SIMS, D. A.; ROBERTS, D. A. Mapping Canadian boreal forest vegetation using pigment and water absorption features derived from the AVIRIS sensor. **Journal of Geophysical Research-Atmospheres**, v. 106, n. D24, p. 33565-33577, 2001.

FYLLAS, N.M.; PATIÑO, S.; BAKER, T.R.; BIELEFELD NARDOTO, G.; MARTINELLI, L.A.; QUESADA, C.A.; PAIVA, R.; SCHWARZ, M.; HORNA, V.; MERCADO, L.M.; SANTOS, A.; ARROYO, L.; JIMÉNEZ, E.M.; LUIZÃO, F.J.; NEILL, D.A.; SILVA, N.; PRIETO, A.; RUDAS, A.; SILVIERA, M.; VIEIRA, I.C.G.; LOPEZ-GONZALEZ, G.; MALHI, Y.; PHILLIPS, O. L.; LLOYD, J. Basin-wide variations in foliar properties of Amazonian forest: phylogeny, soils and climate. **Biogeosciences**, v. 6, n. 11, 2009.

GAMON J.A.; SERRANO L.; SURFUS J.S. The photochemical reflectance index: an optical indicator of photosynthetic radiation-use efficiency across species, functional types, and nutrient levels. **Oecologia**, v. 112, n. 4, p. 492-501, 1997.

GAMON, J.A., SURFUS, J.S. Assessing leaf pigment content and activity with a reflectometer, **New Phytologist**, v. 143, n. 1, p. 105-117, 1999.

GANDOLFI, S.; JOLY, C. A.; RODRIGUES, R. R. Permeability-impermeability: canopy trees as biodiversity filters. **Scientia Agricola**, v. 64, n. 4, p. 433-438, 2007.

GAO, B.C. NDWI – a normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257-266, 1996.

GARCÍA-HARO, F. J.; SOMMER, S. A fast canopy reflectance model to simulate realistic remote sensing scenarios. **Remote Sensing of Environment**, v.81, n.2-3, p.205-227, 2002.

GASTELLU-ETCHEGORRY, J.P.; DEMAREZ, V.; PINEL, V.; ZAGOLSKI, F. Modeling radiative transfer in heterogeneous 3-D vegetation canopies. **Remote Sensing of Environment**, v.58, n. 2, p. 131-156, 1996.

- GASTELLU-ETCHEGORRY, J.P.; MARTIN, E.; GASCON, F. DART: a 3D model for simulating satellite images and studying surface radiation budget. **International Journal of Remote Sensing**, v.25, n. 1, p. 73-96, 2004.
- GASTELLU-ETCHEGORRY, J.P.; MARTIN, E.; GASCON, F. DART: a 3D model for simulating satellite images and studying surface radiation budget. **International Journal of Remote Sensing**, v.25, n. 1, p. 73-96, 2004.
- GASTELLU-ETCHEGORRY, J-P, et al., (2015). Discrete Anisotropic Radiative Transfer (DART 5) for modeling airborne and satellite spectroradiometer and LIDAR acquisitions of natural and urban landscapes. **Remote Sensing**, 7, 1667-1701.
- GATES, D. M.; KEEGAN, H. J.; SCHLETER, J. C.; WEIDNER, V. R. Spectral properties of plants. **Applied Optics**, v. 4, n. 1, 1965.
- GHOSH, A.; FASSNACHT, F. E.; JOSHI, P. K.; KOCH, B. A framework for mapping tree species combining hyperspectral and LiDAR data: role of selected classifiers and sensor across three spatial scales. **International Journal of Applied Earth Observation and Geoinformation**, v. 26, p. 49-63, 2014.
- GITELSON, A.A.; MERZLYAK, M.N.; LICHTENTHALER, H.K. Detection of red edge position and chlorophyll content by reflectance measurements near 700 nm. **Journal of Plant Physiology**, v. 148, n. 3-4, p. 501-508, 1996.
- GITELSON, A.A.; MERZLYAK, M.N.; CHIVKUNOVA, O.B. Optical properties and non-destructive estimation of anthocyanin content in plant leaves. **Photochemistry and photobiology**, v. 74, n. 1, p. 38-45, 2001.
- GITELSON, A.A.; KAUFMAN, Y.J.; STARK, R.; RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote sensing of Environment**, v. 80, n. 1, p. 76-87, 2002a.
- GITELSON, A.A. ; ZUR, Y. ; CHIVKUNOVA, O.B.; MERZLYAK, M.N. Assessing carotenoid content in plant leaves with reflectance spectroscopy. **Photochemistry and photobiology**, v. 75, n. 3, p. 272-281, 2002b.
- GOEL, N. S. Models of vegetation canopy reflectance and their use in estimation of biophysical parameters from reflectance data. **Remote Sensing Reviews**, v.3, p.1-212, 1988.
- GOETZ, A.; VANE, G. Imaging spectrometry for earth remote sensing. **Science**, v. 228, n. 4704, p. 1147-1153, 1985.
- GREEN, R. O.; EASTWOOD, M. L.; SARTURE, C. M.; CHRIEN, T. G.; ARONSSON, M.; CHIPPENDALE, B. J.; FAUST, J. A.; PAVRI, B. E.; CHOVIT, C. J.; SOLIS, M.; OLAH, M. R.; WILLIAMS, O. Imaging Spectroscopy and the Airborne Visible / Infrared Imaging Spectrometer (AVIRIS). **Remote Sensing of Environment**, v. 65, n. 3, p. 227-248, 1998.

GUARATINI, M. T. G.; GOMES, E. C. P.; TAMASHIRO, J. Y.; RODRIGUES, R. R. Composição florística da Reserva Municipal de Santa Genebra, Campinas , SP. **Revista Brasileira de Botânica**, v. 31, n. 2, p. 323-337, 2008.

GUO, L.; CHEHATA, N.; MALLET, C.; BOUKIR, S. Relevance of airborne LiDAR and multispectral image data for urban scene classification using random forests. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 1, p. 56-66, 2011.

GUYON, I.; ELISSEEFF, A. An introduction to variable and feature selection. **Journal of machine learning research**, v. 3, n. Mar, p. 1157-1182, 2003.

HAPKE, B. **Theory of reflectance and emittance spectroscopy**. Cambridge, England : Cambridge University, 2012. p.513 ISBN 978-0-521-88349-8.

HESKETH, M.; SÁNCHEZ-AZOFEIFA, G. A. The effect of seasonal spectral variation on species classification in the Panamanian tropical forest. **Remote Sensing of Environment**, v. 118, p. 73-82, 2012.

HOLLANDER, M., WOLFE, D.A. **Nonparametric statistical methods**, 2. ed. New York: Wiley, 1999, 848 p.

HORLER, D.N.H.; DOCKRAY, M.; BARBER, J. The red-edge of plant leaf reflectance. **International Journal of Remote Sensing**, v. 4, n. 2, p. 273-288, 1983.

HOUBORG, R.; MCCABE, M.; CESCATTI, A.; GAO, F.; SCHULL, M.; GITELSON, A. Joint leaf chlorophyll content and leaf area index retrieval from Landsat data using a regularized model inversion system (REGFLEC). **Remote Sensing of Environment**, v. 159, p. 203-221, 2015.

HUETE, A.R.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E.P.; GAO, X.; FERREIRA, L.G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote sensing of environment**, v. 83, n. 1, p. 195-213, 2002.

HUGHES, G.F. On the mean accuracy of statistical pattern recognizers. **IEEE transactions on information theory**, v. 14, n. 1, p. 55-63, 1968.

HUNT, E.R.; ROCK, B.N. Detection of changes in leaf-water content using near infrared and middle-infrared reflectances. **Remote sensing of environment**, v. 30, n. 1, p. 43-54, 1989.

ITT VISUAL INFORMATION SOLUTIONS. **Atmospheric correction module: QUAC and FLAASH user's guide**. version 4.7. Boulder, CO: ITT Visual Information Solutions, 2009.

JACQUEMOUD, S.; BARET, F. PROSPECT: A model of leaf optical properties spectra. **Remote Sensing of Environment**, v. 34, n. 2, p. 75-91, 1990.

JACQUEMOUD, S.; VERHOEF, W.; BARET, F.; BACOUR, C.; ZARCO-TEJADA, P. J.; ASNER, G. P.; FRANÇOIS, C.; USTIN, S. L. PROSPECT+SAIL models: A review of use for vegetation characterization. **Remote Sensing of Environment**, v. 113, n. supplement 1, p. S56-S66, set. 2009.

JAHNKE, L. S.; LAWRENCE, D. B. Influence of photosynthetic crown structure on potential productivity of vegetation, based primarily on mathematical models. **Ecology**, v.46, n. 3, p. 319-326, 1965.

JETZ, W., CAVENDER-BARES, J., PAVLICK, R., SCHIMEL, D., DAVIS, F. W., ASNER, G. P., GURALNICK, R.; KATTEGE, J.; LATIMER, A. M.; MOORCROFT, P.; SCHAEPMAN, M. E.; SCHILDHAUER, M. P.; SCHNEIDER, F. D.; SCHRODT, F.; STAHL, U.; USTIN, S. L. Monitoring plant functional diversity from space. **Nature plants**, v. 2, p. 16024, 2016.

JIA, X.; RICHARDS, J. A. Segmented principal components transformation for efficient hyperspectral remote-sensing image display and classification. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 1, p. 538-542, 1999.

JUPP, D. L. B.; WALKER, J.; PENRIDGE, L. K. Interpretation of vegetation structure in Landsat MSS imagery: a case study in disturbed semi-arid eucalypt woodland. Part 2: model based analysis. **Environmental Management**, v.23, p.35-57, 1986.

KAILATH, T. The Divergence and bhattacharyya distance measures in signal selection, **IEEE Transactions on Communication Technology**, v. 15, n. 1, p. 52-60, 1967.

KALACSKA, M.; SANCHEZ-AZOFEIFA, G. A.; RIVARD, B.; CAELLI, T.; WHITE, H. P.; CALVO-ALVARADO, J. C. Ecological fingerprinting of ecosystem succession: Estimating secondary tropical dry forest structure and diversity using imaging spectroscopy. **Remote Sensing of Environment**, v. 108, n. 1, p. 82-96, 2007.

KAUFMAN, Y.J.; TANRÉ, D.; REMER, L.A.; VERMOTE, E.F.; CHU, A.; HOLBEN, B.N. Operational remote sensing of tropospheric aerosol over land from EOS moderate resolution imaging spectroradiometer. **Journal of Geophysical Research: Atmospheres**, v. 102, n. D14, p. 17051-17067, 1997.

KIM, M. S. **The use of narrow spectral bands for improving remote sensing estimation of fractionally absorbed Photosynthetically Active Radiation (fAPAR)**. 1994. Dissertação (Mestrado em Geografia) - University of Maryland, College Park, 1994.

KIMES, D.S.; KIRCHNER, J.A. Radiative transfer model for heterogeneous 3-D scenes. **Applied Optics**, v. 21, n. 22, p. 4119-4129, 1982.

KIMES, D. S.; NELSON, R. F.; MANRY, M. T.; FUNG, A. K. Review article: Attributes of neural networks for extracting continuous vegetation variables from optical and radar measurements. **International journal of remote sensing**, v. 19, n. 14, p. 2639-2663, 1998.

- KOHAVI, R.; JOHN, G.H. Wrappers for feature subset selection. **Artificial intelligence**, v. 97, n. 1-2, p. 273-324, 1997.
- KOKALY, R.F. Investigating a physical basis for spectroscopic estimates of leaf nitrogen concentration. **Remote Sensing of Environment**, v. 75, n. 2, p. 153-161, 2001.
- KOKALY, R. F.; DESPAIN, D. G.; CLARK, R. N.; LIVO, K. E. Mapping vegetation in Yellowstone National Park using spectral feature analysis of AVIRIS data. **Remote Sensing of Environment**, v. 84, n. 3, p. 437-456, 2003.
- KOKALY, R.F.; ASNER, G.P.; OLLINGER, S.V.; MARTIN, M.E.; WESSMAN, C.A. Characterizing canopy biochemistry from imaging spectroscopy and its application to ecosystem studies. **Remote Sensing of Environment**, v. 113, p. S78-S91, 2009.
- KUBELKA, P.; MUNK, F. Ein beitrag zur optik der farbanstriche. **Zeitschrift für Technische Physik**, v.12, p.593–601, 1931.
- LABEN, C. A.; BROWER, B.V. **Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening**. U.S. Patent n. 6,011,875, 4 jan. 2000.
- LAGARIAS, J. C.; REEDS, J. A.; WRIGHT, M. H.; WRIGHT, P. E. Convergence properties of the Nelder-Mead simplex method in low dimensions. **SIAM Journal on Optimization**, v. 9, n. 1, p. 112-147, 1998.
- LAMBONI, M.; MONOD, H.; MAKOWSKI, D. Multivariate sensitivity analysis to measure global contribution of input factors in dynamic models. **Reliability Engineering & System Safety**, v. 96, n. 4, p. 450-459, 2011.
- LE MAIRE, G.; FRANCOIS, C.; DUFRENE, E. Towards universal broad leaf chlorophyll indices using PROSPECT simulated database and hyperspectral reflectance measurements. **Remote sensing of environment**, v. 89, n. 1, p. 1-28, 2004.
- LEITÃO FILHO, H. de F. Aspectos taxonômicos das florestas do Estado de São Paulo. **Silvicultura em São Paulo**, v. 16, n. 1, p. 197-206, 1982.
- LEONENKO, G.; LOS, S.O.; NORTH, P.R.J. Statistical distances and their applications to biophysical parameter estimation: Information measures, M-estimates, and minimum contrast methods. **Remote Sensing**, v. 5, n. 3, p. 1355-1388, 2013.
- LESICA, P.; ALLENDORF, F.W. Ecological genetics and the restoration of plant communities: mix or match?. **Restoration ecology**, v. 7, n. 1, p. 42-50, 1999.
- LI, X.; STRAHLER, A. H. Geometric-optical modeling of a conifer forest canopy. **IEEE Transactions on Geoscience and Remote Sensing**, v. 23, p. 705-721, 1985.

- LIAW, A.; WIENER, M. Classification and regression by randomForest. **R news**, v. 2, n. 3, p. 18-22, 2002.
- MALENOVSKÝ, Z.; ALBRECHTOVÁ, J.; LHOTÁKOVÁ, Z.; ZURITA-MILLA, R.; CLEVERS, J. G. P. W.; SCHAEPMAN, M. E.; CUDLÍN, P. Applicability of the PROSPECT model for Norway spruce needles. **International Journal of Remote Sensing**, v. 27, n. 24, p. 5315–5340, 2006.
- MALENOVSKÝ, Z.; HOMOLOVÁ, L.; ZURITA-MILLA, R.; LUKEŠ, P.; KAPLAN, V.; HANUŠ, J.; GASTELLU-ETCHEGORRY, J. P.; SCHAEPMAN, M. E. Retrieval of spruce leaf chlorophyll content from airborne image data using continuum removal and radiative transfer. **Remote Sensing of Environment**, v.131, p. 85-102, 2013.
- MALENOVSKÝ, Z.; MARTIN, E.; HOMOLOVÁ, L.; GASTELLU-ETCHEGORRY, J.-P.; ZURITA-MILLA, R.; SCHAEPMAN, M. E.; POKORNÝ, R.; CLEVERS, J.G.W.; CUDLÍN, P. Influence of woody elements of a Norway spruce canopy on nadir reflectance simulated by the DART model at very high spatial resolution. **Remote Sensing of Environment**, v. 112, n. 1, p. 1-18, 2008.
- MELGANI, F.; BRUZZONE, L. Classification of hyperspectral remote sensing images with support vector machines. **IEEE Transactions on Geoscience and Remote Sensing**, v. 42, n. 8, p. 1778-1790, 2004.
- MENZE, B. H.; KELM, B. M.; MASUCH, R.; HIMMELREICH, U.; BACHERT, P.; PETRICH, W.; HAMPRECHT, F. A. A comparison of random forest and its Gini importance with standard chemometric methods for the feature selection and classification of spectral data. **BMC bioinformatics**, v. 10, n. 1, p. 213, 2009.
- MERZLYAK, M. N.; GITELSON, A. A.; CHIVKUNOVA, O. B.; RAKITIN, V. Y. Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. **Physiologia plantarum**, v. 106, n. 1, p. 135-141, 1999.
- MERZLYAK, M.N.; GITELSON, A.A.; CHIVKUNOVA, O.B.; AND RAKITIN, Y. Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening, **Physiologia plantarum**, v. 106, n. 1, p. 135-141, 1999.
- MORELLATO, L. P. C. **Estudo da fenologia de árvores, arbustos e lianas de uma floresta semidecídua no sudeste do Brasil**. 1991. 176 p. Tese (Doutorado em Biologia) - Universidade Estadual de Campinas (UNICAMP), Campinas, 1991.
- MORTON, D. C.; RUBIO, J.; COOK, B. D.; GASTELLU-ETCHEGORRY, J. P.; LONGO, M.; CHOI, H.; HUNTER, M.; KELLER, M. Amazon forest structure generates diurnal and seasonal variability in light utilization. **Biogeosciences**, v. 13, n. 7, p. 2195, 2016.
- MYERS, N.; MITTERMEIER, R. A.; MITTERMEIER, C. G.; FONSECA, G. A.; KENT, J. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. 6772, p. 853-858, 2000.

OLIVEIRA, A. C. S.; SOUZA, A. A.; LACERDA, W. S.; GONÇALVES, L. R. Aplicação de redes neurais artificiais na previsão da produção de álcool. **Ciência e Agrotecnologia**, v. 34, n. 2, p. 279-284, 2010.

PACIFICI, F. An automatic atmospheric compensation algorithm for very high spatial resolution imagery and its comparison to QUAC and FLAASH. In: JOINT AGENCY COMMERCIAL IMAGERY EVALUATION (JACIE), 2013, Saint Louis, MO, USA. **Proceedings...** 2013. p. 16-18.

PACIFICI, F.; LONGBOTHAM, N.; EMERY, W.J. The importance of physical quantities for the analysis of multitemporal and multiangular optical very high spatial resolution images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 10, p. 6241-6256, 2014

PAL, M. Random forest classifier for remote sensing classification. **International Journal of Remote Sensing**, v. 26, n. 1, p. 217-222, 2005.

PAL, M.; MATHER, P.M. Support vector machines for classification in remote sensing. **International Journal of Remote Sensing**, v. 26, n. 5, p. 1007-1011, 2005.

PAPES, M.; TUPAYACHI, R.; MARTÍNEZ, P.; PETERSON, A.T.; POWELL, G.V.N. Using hyperspectral satellite imagery for regional inventories: a test with tropical emergent trees in the Amazon Basin. **Journal of Vegetation Science**, v. 21, p. 342-354, 2010.

PEÑUELAS, J.; BARET, F.; FILELLA, I. Semi-empirical indices to assess carotenoids/ chlorophyll-a ratio from leaf spectral reflectance. **Photosynthetica**, v. 31, n. 2, p. 221-230, 1995.

PONZONI, F.J.; SHIMABUKURO, Y.E.; KUPLICH, T.M. **Sensoriamento remoto da vegetação**, 2012. 160 p.

PRICE, J. C. How unique are spectral signatures? **Remote Sensing of Environment**, v. 49, n. 3, p. 181-186, 1994.

QIN, W.; GERSTL, S. A. W. 3-D Scene modeling of semidesert vegetation cover and **Remote Sensing**, v.25, n.1, p.75-96, 2004.

REES, W. G. **Physical principles of remote sensing**. Cambridge, England : Cambridge University, 2013.

RIBEIRO M.C.; METZGER J.P.; MARTENSEN A.C.; PONZONI F.J.; HIROTA M.M. The Brazilian Atlantic Forest: how much is left, and how the remaining forest distributed? Implications for conservation. **Biological Conservation**, v. 142, n.6, p. 1141-1153, 2009.

RICHTER, R.; REU, B.; WIRTH, C.; DOKTOR, D.; VOHLAND, M. The use of airborne hyperspectral data for tree species classification in a species-rich Central European forest area. **International Journal of Applied Earth Observation and Geoinformation**, v. 52, p. 464-474, 2016.

ROBERTS, D.A. ; ROTH, K.L. ; PERROY, R.L. Hyperspectral vegetation indices. In: THENKABAIL, P.S.; LYON, J.G.; HUETE, A. (Eds.). **Hyperspectral remote sensing of vegetation**. London: CRC Press, Taylor & Francis Group, 2011. p. 309–327. ISBN 9781439845370. Disponível em: <[http://www.crcpress.com/ecommerce\\_product/product\\_detail.jsf?isbn=0&catno=k12019](http://www.crcpress.com/ecommerce_product/product_detail.jsf?isbn=0&catno=k12019)>. Acesso em: 15 mar. 2015.

ROSS, J. **The radiation regime and architecture of plant stands**. The Hague-Boston-London: Dr W. Junk Publishers, 1981. 391p.

ROUSE, J.W., HAAS, R.H., SCHELL, J.A., DEERING, D.W., 1973. Monitoring vegetation systems in the Great Plains with ERTS. In: ERTS-1 SYMPOSIUM, 3., 1973, Washington. **Proceedings...** Washington: Scientific and Technical Information Office, National Aeronautics and Space Administration, 1973. p. 309–317.

SANTOS, T. B. **Sensoriamento remoto na análise de mudanças da cobertura florestal na Serra da Mantiqueira, entre 1989 a 2011**. 2013. 267 p. (sid.inpe.br/mtc-m19/2013/08.23.15.12-TDI). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2013. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3EMJPML>>.

SCHLERF, M.; ATZBERGER, C. Inversion of a forest reflectance model to estimate structural canopy variables from hyperspectral remote sensing data. **Remote sensing of environment**, v. 100, n. 3, p. 281-294, 2006.

SCHNEIDER, F. D.; LEITERER, R.; MORSDORF, F.; GASTELLU-ETCHEGORRY, J.-P.; LAURET, N.; PFEIFER, N.; SCHAEPMAN, M. E. Simulating imaging spectrometer data: 3D forest modeling based on LiDAR and in situ data. **Remote Sensing of Environment**, v. 152, p. 235-250, 2014.

SERRANO, L.; PEÑUELAS, J.; USTIN, S.L. Remote sensing of nitrogen and lignin in Mediterranean vegetation from AVIRIS data: Decomposing biochemical from structural signals, **Remote Sensing of Environment**, v. 81, n. 2, p. 355-364, 2002.

SHAPIRO, L.; STOCKMAN, G.C. **Computer vision**. Prentice Hall, 2001, 617 p.

SMOLANDER, S.; STENBERG, P. A method to account for shoot scale clumping in coniferous canopy reflectance models. **Remote Sensing of Environment**, v. 88, n. 4, p. 363-373, 2003.

SOS MATA ATLÂNTICA / INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (SOS/INPE). **Atlas dos remanescentes florestais da Mata Atlântica, Período de 2013 a 2014**. 2015. Disponível em: <[mapas.sosma.org.br](http://mapas.sosma.org.br)>. Acesso em: 13 nov. 2016.

SOUZA, F.M.; GANDOLFI, S.; RODRIGUES, R.R. Deciduousness Influences the Understory Community in a Semi-deciduous Tropical Forest. **Biotropica**, v. 46, n. 5, p. 512-515, 2014.

TAIZ, L.; ZEIGER, E. **Plant physiology**. 5. ed. Sinauer Associates, 2010. 782 p.

TILMAN, D. Functional diversity. **Encyclopedia of biodiversity**, v. 3, n. 1, p. 109-120, 2001.

TOCHON, G.; FÉRET, J.B.; VALERO, S.; MARTIN, R.E.; KNAPP, D.E.; SALEMBIER, P.; CHANUSSOT, J.; ASNER, G.P. On the use of binary partition trees for the tree crown segmentation of tropical rainforest hyperspectral images. **Remote Sensing of Environment**, v. 159, p. 318-331, 2015.

UNGAR, S.G.; REUTER, D.; PEARLMAN, J.S.; MENDENHALL, J.A. Overview of the Earth Observing One (EO-1) mission. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 6, p. 1149–1159, 2003.

VAPNIK, V.N. **The nature of statistical learning theory**. 2. ed. New York: Springer, 2000, 313 p.

VELOSO, H.P.; RANGEL FILHO, A.L.R.; LIMA, J.C.A. **Classificação da vegetação brasileira, adaptada a um sistema universal**. Rio de Janeiro: IBGE, 1991.

VERHOEF, W. Light scattering by leaf layers with application to canopy reflectance modeling: the SAIL model. **Remote Sensing of Environment**, v.16, n.2, p.125-141, 1984.

VERHOEF, W.; JIA, L.; XIAO, Q.; SU, Z. Unified optical-thermal four-stream radiative transfer theory for homogeneous vegetation canopies. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 6, p. 1808-1822, 2007.

WACKER, A. G. **The minimum distance approach to classification**. Tese de Doutorado, Purdue University, West Lafayette, 1971.

WEISS, M.; BARET, F.; MYNENI, R.; PRAGNÈRE, A.; KNYAZIKHIN, Y. Investigation of a model inversion technique to estimate canopy biophysical variables from spectral and directional reflectance data. **Agronomie**, v. 20, n. 1, p. 3-22, 2000.

WESSMAN, C. A.; ABER, J. D.; PETERSON, D. L.; MELILLO, J. M. Remote sensing of canopy chemistry and nitrogen cycling in temperate forest ecosystems. **Nature**, v. 335, p. 154-156, 1988.

WIDLÓWSKI, J. L.; TABERNER, M.; PINTY, B.; BRUNIQUEL-PINEL, V.; DISNEY, M.; FERNANDES, R.; GASTELLU-ETCHEGORY, J.P.; GOBRON, N.; KUUSK, A.; LAVERGNE, T.; LEBLANC, S.; LEWIS, P.E.; MARTIN, E.; MÖTTUS, M. NORTH, P.R.J.; QIN, W.; ROBUSTELLI, M.; ROCHDI, N.; RUILOBA, R.; SOLAR, C.; THOMPSON, R.; VERHOEF, W.; VERSTRAETE, M.M.; XIE, D. Third Radiation Transfer Model Intercomparison (RAMI)

exercise: Documenting progress in canopy reflectance models. **Journal of Geophysical Research-Atmospheres**, v. 112, n. D9, 2007.

WIDLOWSKI, J.-L.; MIO, C.; DISNEY, M.; ADAMS, J.; ANDREDAKIS, I.; ATZBERGER, C.; BRENNAN, J.; BUSETTO, L.; CHELLE, M.; CECCHERINI, G.; COLOMBO, R.; CÔTÉ, J.-F.; EENMÄE, A.; ESSERY, R.; GASTELLU-ETCHEGORRY, J.-P.; GOBRON, N.; GRAU, E.; HAVERD, V.; HOMOLOVÁ, L.; HUANG, H.; HUNT, L.; KOBAYASHI, H.; KOETZ, B.; KUUSK, A.; KUUSK, J.; LANG, M.; LEWIS, P. E.; LOVELL, J. L.; MALENOVSKÝ, Z.; MERONI, M.; MORSDORF, F.; MÖTTUS, M.; NI-MEISTER, W.; PINTY, B.; RAUTIAINEN, M.; SCHLERF, M.; SOMERS, B.; STUCKENS, J.; VERSTRAETE, M. M.; YANG, W.; ZHAO, F.; ZENONE, T. The fourth phase of the radiative transfer model intercomparison (RAMI) exercise: actual canopy scenarios and conformity testing. **Remote Sensing of Environment**, n. 169, p. 418-437, 2015.

WRIGHT, I. J.; REICH, P. B.; WESTOBY, M.; ACKERLY, D. D.; BARUCH, Z.; BONGERS, F.; CAVENDER-BARES, J.; CHAPIN, T.; CORNELISSEN, J. H. C.; DIEMER, M.; FLEXAS, J.; GARNIER, E.; GROOM, P. K.; GULIAS, J.; HIKOSAKA, K.; LAMONT, B. B.; LEE, T.; LEE, W.; LUSK, W.; MIDGLEY, J. J.; NAVAS, M.-L.; NIINEMETS, U.; OLEKSYN, J.; OSADA, J.; POORTER, H.; POOT, P.; PRIOR, L.; PYANKOV, V. I.; ROUMET, C.; THOMAS, S. C.; TJOELKER, M. G.; VENEKLAAS, E. J.; VILLAR, R. The worldwide leaf economics spectrum. **Nature**, v. 428, n. 6985, p. 821-827, 2004.

XIAO, Y.; ZHAO, W.; ZHOU, D.; GONG, H. Sensitivity analysis of vegetation reflectance to biochemical and biophysical variables at leaf, canopy, and regional scales. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 7, p. 4014-4024, 2014.

YEGNANARAYANA, B. **Artificial neural networks**. PHI Learning. 2009, 463p.

ZANOTTA, D. C. **Uma metodologia adaptativa baseada em objetos para detecção semisupervisionada de desflorestamento na amazônia**. 2014. 139 p. IBI: <8JMKD3MGP5W34M/3G3F7H5>. (sid.inpe.br/mtc-m21b/2014/04.01.05.56-TDI). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2014. Disponível em: <<http://urlib.net/8JMKD3MGP5W34M/3G3F7H5>>.

ZARCO-TEJADA, P. J.; GUILLÉN-CLIMENT, M. L.; HERNÁNDEZ-CLEMENTE, R.; CATALINA, A.; GONZÁLEZ, M. R.; MARTÍN, P. Estimating leaf carotenoid content in vineyards using high resolution hyperspectral imagery acquired from an unmanned aerial vehicle (UAV). **Agricultural and Forest Meteorology**, v. 171, p. 281-294, 2013.

ZARCO-TEJADA, P.J.; MILLER, J.R.; HARRON, J.; HU, B.; NOLAND, T.L.; GOEL, N.; MOHAMMED, G.H.; SAMPSON, P. Needle chlorophyll content estimation through model inversion using hyperspectral data from boreal conifer forest canopies. **Remote Sensing of Environment**, v. 89, n. 2, p. 189-199, 2004a.

ZARCO-TEJADA, P.J.; MILLER, J.R.; MORALES, A.; BERJÓN, A.; AGÜERA, J. Hyperspectral indices and model simulation for chlorophyll estimation in open-canopy tree crops. **Remote Sensing of Environment**, v. 90, n. 4, p. 463-476, 2004b.

ZHANG, J.; RIVARD, B.; SANCHEZ-AZOFEIFA, G.A.; CASTRO-ESAU, K. Intra and interclass spectral variability of tropical tree species at La Selva, Costa Rica: Implications for species identification using HYDICE imagery. **Remote Sensing of Environment**, v. 105, n. 2, p.129-141, 2006.

ZHANG, Y.; CHEN, J.M.; MILLER, J.R.; NOLAND, T.L. Leaf chlorophyll content retrieval from airborne hyperspectral remote sensing imagery. **Remote Sensing of Environment**, v. 112, n. 7, p. 3234–3247, 2008.