

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

sid.inpe.br/mtc-m21b/2017/04.20.20.03-TDI

# USO DE DIFERENTES CLASSIFICADORES E DE SIMULAÇÃO ESTOCÁSTICA PARA DISCRIMINAÇÃO DE FITOFISIONOMIAS DO CERRADO USANDO ATRIBUTOS HIPERESPECTRAIS DO SENSOR HYPERION/EO-1

Alana Carla Toniol

Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelo Dr. Lênio Soares Galvão, aprovada em 11 de Abril de 2017.

URL do documento original: <http://urlib.net/ 8JMKD3MGP3W34P/3NNR6DB>

> 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 Ducca 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/2017/04.20.20.03-TDI

# USO DE DIFERENTES CLASSIFICADORES E DE SIMULAÇÃO ESTOCÁSTICA PARA DISCRIMINAÇÃO DE FITOFISIONOMIAS DO CERRADO USANDO ATRIBUTOS HIPERESPECTRAIS DO SENSOR HYPERION/EO-1

Alana Carla Toniol

Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelo Dr. Lênio Soares Galvão, aprovada em 11 de Abril de 2017.

URL do documento original: <http://urlib.net/ 8JMKD3MGP3W34P/3NNR6DB>

> INPE São José dos Campos 2017

Dados Internacionais de Catalogação na Publicação (CIP)

Toniol, Alana Carla.

T613u Uso de diferentes classificadores e de simulação estocástica para discriminação de fitofisionomias do Cerrado usando atributos hiperespectrais do sensor Hyperion/EO-1 / Alana Carla Toniol. – São José dos Campos : INPE, 2017.

xxii + 122 p. ; (sid.inpe.br/mtc-m21b/2017/04.20.20.03-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2017. Orientador : Dr. Lênio Soares Galvão.

1. Cerrado. 2. Classificação. 3. Hiperespectral. 4. Simulação estocástica. I. Título.

CDU 528.8(213.54)



Esta obra foi licenciada sob uma Licença Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada.

This work is licensed under a Creative Commons Attribution-NonCommercial 3.0 Unported License.

Aluno (a): Alana Carla Toniol

Título: "USO DE DIFERENTES CLASSIFICADORES E DE SIMULAÇÃO ESTOCÁSTICA PARA DISCRIMINAÇÃO DE FITOFISIONOMIAS DO CERRADO USANDO ATRIBUTOS HIPERESPECTRAIS DO SENSOR HYPERION/EO-1"

> Aprovado (a) pela Banca Examinadora em cumprimento ao requisito exigido para obtenção do Título de Mestre em

Sensoriamento Remoto

Dr. Flávio Jorge Ponzoni

manni

Presidente / INPE / SJCampos - SP

Dr. Lênio Soares Galvão

Orientador(a) / INPE / SJCampos - SP

leda Del' Arco Sanches Dra.

Jeda Del'anco Sanch

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

Dr. Edson Eyji Sano

Convidado(a) / EMERAPA / Brasília - DF

Este trabalho foi aprovado por:

- () maioria simples
- (以) unanimidade

"Não te mandei eu? Esforça-te, e tem bom ânimo; não temas, nem te espantes; porque o Senhor teu Deus é contigo, por onde quer que andares."

Josué 1:9

#### AGRADECIMENTOS

Agradeço a Deus pelo dom da vida e pela capacidade de raciocínio e discernimento.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão da bolsa de mestrado e ao Programa de Pós-Graduação em Sensoriamento Remoto do Instituto Nacional de Pesquisas Espaciais (INPE) pelo apoio financeiro e disponibilização de seus recursos e instalações para o desenvolvimento deste estudo.

Ao Dr. Lênio Soares Galvão por sua exímia orientação e pela confiança, paciência e disposição durante o ensino e auxílio em todas as etapas da elaboração deste trabalho.

Ao Dr. Flávio Jorge Ponzoni por aceitar participar da elaboração deste estudo, contribuindo para o melhor desenvolvimento do trabalho, bem como para o meu crescimento profissional por meio dos conhecimentos repassados.

Ao Dr. Camilo Daleles Rennó por disponibilizar seu tempo e conhecimento no auxílio das análises estatísticas deste estudo; e aos demais professores e servidores do INPE, pela dedicação e apoio prestados durante o tempo de aprendizado.

Ao Dr. Edson Eyji Sano, pesquisador da Embrapa Cerrados e chefe do Centro de Sensoriamento Remoto do IBAMA, por sua generosidade e pelos conhecimentos a mim repassados. Agradeço ainda a sua imensa contribuição durante a realização do trabalho de campo no reconhecimento da área de estudo do Parque Nacional de Brasília (PNB).

Ao analista ambiental do IBAMA/CSR Daniel Moraes de Freitas por sua participação e apoio prestado durante o trabalho de campo no PNB. Agradeço por sua presteza e pelos momentos de descontração vivenciados durante a realização das atividades.

Ao Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio) pela autorização concedida para realização do trabalho de campo no PNB, e à Embrapa Cerrados, em especial, ao chefe-geral Dr. Cláudio Takao Karia, por ter gentilmente cedido um veículo do centro para a condução das pesquisas de campo.

Ao amigo Diogo por me lembrar da complexidade que rege a vida e por demonstrar paciência e generosidade ao repassar seus conhecimentos visando sempre ao meu crescimento pessoal e profissional.

Aos meus colegas do curso de mestrado que sempre se mostraram dispostos a garantir a alegria e o companheirismo nos momentos mais difíceis dessa jornada.

A minha família que jamais desistiu de investir em meus estudos e que sempre me apoiou nas decisões que me fizeram chegar até aqui.

#### RESUMO

O Cerrado brasileiro é considerado um dos mais importantes ecossistemas do mundo tanto pela riqueza de fauna quanto por sua ampla diversidade de espécies herbáceas, arbustivas e arbóreas que ocorrem em um gradiente de vegetação bem definido. Tendo em vista a importância do monitoramento desse hotspot de biodiversidade, o sensoriamento remoto hiperespectral pode fornecer informações sobre as características biofísicas e bioquímicas de sua cobertura vegetal. O objetivo deste trabalho foi identificar o melhor conjunto de atributos hiperespectrais do sensor Hyperion/Earth Observing One (EO-1), testando o desempenho de diferentes técnicas de classificação supervisionadas com esses atributos para discriminação de fitofisionomias do Cerrado. Na etapa de classificação foram consideradas duas imagens referentes à estação chuvosa (13/01/2015) e seca (24/06/2015). A área de estudo foi o Parque Nacional de Brasília (PNB). Os atributos testados foram: (a) a reflectância de 146 bandas do sensor Hyperion; (b) a primeira derivada da reflectância; (c) 22 índices de vegetação (IVs) de bandas estreitas; (d) a profundidade, área, largura e assimetria das bandas de absorção de clorofila em 680 nm; água foliar em 980 e 1200 nm; lignina e celulose em 1700, 2100 e 2300 nm; e (e) todos os atributos em conjunto. Os classificadores testados foram Árvore de Decisão J48 (AD), Random Forest (RF), Spectral Angle Mapper (SAM) e Support Vector Machine (SVM). Os resultados mostraram que a maior quantidade de atributos selecionados no período chuvoso compensou as confusões espectrais associadas à estrutura da vegetação durante esse período. Bandas mais profundas de absorção de água foram observadas no período chuvoso para as formações arbóreas que apresentaram também maiores taxas de variação espectral associadas à borda vermelha (primeira derivada). As classificações do período chuvoso apresentaram desempenho levemente superior às classificações do período seco, especialmente para tipologias que incluíam espécies invasoras, embora a maioria das diferenças em exatidão de classificação não tenham sido estatisticamente diferentes. As maiores exatidões totais foram atribuídas às classificações com todos os atributos em conjunto, enquanto que as menores exatidões foram relacionadas aos atributos parâmetros de bandas de absorção e derivada de 1ª ordem. Pelos mapas de entropia de Shannon e de moda, observou-se que as maiores incertezas entre os classificadores ocorreram para os atributos derivada de 1ª ordem e parâmetros de bandas de absorção, estando associadas com as fitofisionomias campestres. Pelo processo de simulação estocástica foram confirmados os resultados obtidos pelos mapas de classificação. Considerando um intervalo de credibilidade de 99%, pode-se concluir que os melhores resultados de classificação nos períodos chuvoso e seco foram observados para RF e SVM. Usando estes classificadores, as maiores percentagens de acerto de classificação foram observadas com todos os atributos em conjunto para as formações campestres e com IVs, reflectância e todos os atributos para as formações arbóreas. A utilização de simulação estocástica foi importante para a complementação e confirmação dos resultados estatísticos associados aos processos de classificação de imagens Hyperion.

Palavras-chave: Cerrado. Classificação. Hiperespectral. Simulação estocástica.

## USE OF DIFFERENT CLASSIFIERS AND STOCHASTIC SIMULATION FOR THE DISCRIMINATION OF CERRADO PHYSIOGNOMIES USING HYPERSPECTRAL ATTRIBUTES OF THE HYPERION/EO-1 SENSOR

#### ABSTRACT

The Brazilian savanna, locally known as Cerrado, is one of the most important ecosystems of the world because of the high biodiversity of trees, shrubs and grasses associated with a well-defined vegetation gradient. In order to monitor this important world's hotspot, hyperspectral remote sensing can provide information on biophysical and biochemistry vegetation properties. The objective of this study was to identify the best set of hyperspectral attributes to be used as input to different classification techniques for discriminating the Cerrado physiognomies. In the classification phase, two images were considered in rainy season (01/13/2015) and dry (06/24/2015). The study area is the Parque Nacional de Brasília (PNB). The attributes tested were, as follows: (a) the reflectance of 146 Hyperion bands; (b) the first-order derivative of reflectance; (c) 22 narrowband vegetation indices (VIs); (d) the depth, area, width and asymmetry of the 680-nm chlorophyll absorption band; the 980-nm and 1200-nm leaf water features; the 1700-nm, 2100-nm and 2300-nm lignin/cellulose absorption bands; and (e) all sets of attributes. The classifiers used in the data analysis were Decision Tree J48 (DT), Random Forest (RF), Spectral Angle Mapper (SAM) and Support Vector Machine (SVM). The results showed that the greater spectral confusion in the rainy season than in the dry season was compensated by the selection of a greater number of hyperspectral attributes in the classification procedure. Deeper leaf water absorption bands were observed in the rainy season for the tree-wooded savannas, which showed also greater rates of reflectance changes in the red-edge interval (firstorder derivative). Classification accuracy in the rainy season was slightly higher than in the dry season, especially for classes with invasive species, but most of the differences were not statistically significant. The highest classification accuracy was obtained with the use of all hyperspectral attributes, while the lowest values were noted for the absorption band parameters and first-order derivative of reflectance. These results were confirmed by the Shannon entropy and mode maps, which showed that the greatest uncertainties in the classification were associated with the grassland/shrub savanna physiognomies. From the stochastic simulation at 99% confidence level, it was concluded that the best classification results in both seasons were observed for RF and SVM. Using these classifiers, the largest percentages of correct classification were obtained with all attributes for the grassland/shrub savannas and with reflectance, VIs and all attributes for the tree-wooded physiognomies. Overall, the stochastic simulation was important for complementing and confirming the statistical results associated with the classification of the Hyperion images.

Keywords: Cerrado. Classification. Hyperspectral. Stochastic simulation.

# LISTA DE FIGURAS

Figura 5.8 Classificações das fitofisionomias a partir do atributo reflectância nos períodos chuvoso (Janeiro) e seco (Junho). O mapa de referência foi adaptado de Ferreira (2003a).....63

Figura 5.12 Classificações das fitofisionomias a partir de todos os atributos nos períodos chuvoso (Janeiro) e seco (Junho). O mapa de referência foi adaptado de Ferreira (2003a).....70

 

Figura	5.16	Mapas	de	incerteza	dos	atributos	hiperespectrais	quantificados	por	meio	da
entropia	a de Sł	nannon	•••••						•••••		.77

Figura 5.17 Mapas representativos da moda para cada um dos *pixels* avaliados......78

Figura	5.18	Gráfico	boxplot	das	diferenças	dos	índices	Kappa	entre	as	classificações	dos
período	os seco	o e chuvo	oso									81

Figura	5.19	Percentual	de	acerto	das	fitofisionomias	em	relação	às	cinco	melhores	
classifi	classificações no período chuvoso (Janeiro)											

Figura	5.20	Percentual	de	acerto	das	fitofisionomias	em	relação	às	cinco	melhores
classifi	cações	do período	seco	(Junho)	)						86

# LISTA DE TABELAS

Tabela 3.1 Características das fitofisionomias encontradas no Parque Nacional de Brasília
(PNB)
Tabela 4.1 Características geométricas da coleta de dados nas cenas selecionadas para estudo.
Tabela 4.2 Índices de vegetação (IVs) de bandas estreitas usados para geração de métricas    hiperespectrais
Tabela 5.1. Proporção de brilho explicada pela variação do cosseno dos ângulos zenitais51
Tabela 5.2 Seleção de atributos realizada pelo algoritmo CFS.  61
Tabela 5.3 Matriz de confusão da classificação SVM, no período chuvoso, para o atributo
reflectância e o conjunto separado de <i>pixels</i> de validação64
Tabela 5.4 Matriz de confusão da classificação RF, no período chuvoso, para o atributo
derivada de 1º ordem e o conjunto separado de <i>pixeis</i> de vandação
Tabela 5.5 Matriz de confusão da classificação RF, no período chuvoso, para o atributo índice de vegetação e para o conjunto separado de <i>pixels</i> de validação
Tabela 5.6 Matriz de confusão da classificação RF, no período chuvoso, para o atributo parâmetros de bandas de absorção e para o conjunto separado de <i>pixels</i> de validação 68
parametros de bandas de absorção e para o conjunto separado de <i>pixeis</i> de vandação
Tabela 5.7 Matriz de confusão da classificação SVM, no período chuvoso, para todos os
atributos em conjunto e para o conjunto separado de <i>pixeis</i> de vandação
Tabela 5.8. Exatidão total (E.T.) e índice Kappa dos algoritmos de classificação em relação
Tabela 5.9 Visão geral dos erros de omissão das classificações em relação aos atributos selecionados
Tabela 5.10 Visão geral dos erros de omissão das classificações em relação aos atributos

Tabela 5.11 Exatidão total, ganho e índice Kappa das classificações RF sem a inclusão	das
fitofisionomias Campo Limpo com Murundus (CLM), Campo Cerrado com Trembleias (C	CT)
e Campo Sujo com presença de Arnica e Canela de Ema (CS/A/CE).	76

Tabela	5.12	Métricas	estatísticas	das	distribuições	dos	índices	Kappa,	geradas	para	cada
classific	cação	nos perío	dos chuvoso	e se	co						79

Tabela 5.13 Média do índice Kappa para as classificações dos períodos chuvoso e seco......80

Tabela 5.14	Exatidão	do	usuário	média,	no	período	chuvoso,	para	as	fitofisionomias
campestres e	arbóreas									
Tabela 5.15 I	Exatidão do	o usi	uário méo	lia, no p	erío	do seco, j	para as fito	ofision	omi	as campestres e
arbóreas				-			-			

# LISTA DE SIGLAS E ABREVIATURAS

AD	Árvore de Decisão
ALI	Advanced Land Imager
ARI	Anthocyanin Reflectance Index
CAI	Cellulose Absorption Index
CC	Campo Cerrado
CCT	Campo Cerrado com Trembleias
CFS	Correlation based Feature Selection
CL	Campo Limpo
CLM	Campo Limpo com Murundus
CPAC	Centro de Pesquisa Agropecuária dos Cerrados
CRI1	Carotenoid Reflectance Index 1
CS	Campo Sujo
CS/A/CE	Campo Sujo com Arnica e Canela de Ema
CSS	Cerrado sensu stricto
DT	Decision Tree
EnMAP	Environmental Mapping and Analysis
EnSAG	EnMAP Scientific Advisory Group
EO-1	Earth Observing One
EVI	Enhanced Vegetation Index
FDP	Função de Distribuição de Probabilidade
FLAASH	Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes
HyspIRI	Hyperspectral Infrared Imager
IAF	Índice de Área Foliar
INMET	Instituto Nacional de Meteorologia
IVs	Índices de Vegetação
LAC	Linear etalon imaging spectrometer array Atmospheric Corretor
LWVI2	Leaf Water Vegetation Index 2
MCARI	Modified Chlorophyll Absorption Ratio Index
MDA	Análise Discriminante Múltipla
MG	Mata de Galeria
MLME	Modelo Linear de Mistura Espectral
MODTRAN	Moderate Resolution Transmittance Code
MSI	Moisture Stress Index
NASA	National Aeronautics and Space Administration
NDII	Normalized Difference Infrared Index
NDLI	Normalized Difference Lignin Index
NDVI	Normalized Difference Vegetation Index
NDWI	Normalized Difference Water Index

NIR	Near Infrared
PNB	Parque Nacional de Brasília
PRI	Photochemical Reflectance Index
PRISM	Processing Routines in IDL for Spectroscopic Measurements
PSRI	Plant Senescence Reflectance Index
PSSR	Pigment Specific Simple Ratio
PUK	Pearson VII function-based universal Kernel
RENDVI	Red Edge Normalized Difference Vegetation Index
REP	Red Edge Position
REPI	Red Edge Position Index
RF	Random Forest
RVSI	Red-Edge Vegetation Stress Index
SAM	Spectral Angle Mapper
SIPI	Structure Insensitive Pigment Index
SMO	Optimization Minimal Sequential
SVM	Support Vector Machine
SWIR	Shortwave Infrared
USGS	United States Geological Survey
VARI	Visible Atmospherically Resistant Index
VIg	Visible Index Green
VNIR	Visible-Near Infrared
VOG	Vogelmann Red Edge Index
VSWIR	Visible- Shortwave Infrared
WBI	Water Band Index
WEKA	Waikato Environment for Knowledge Analysis

1	INT	ſROI	DUÇÃO	1
	1.1	Hip	ótese de trabalho	5
	1.2	Obje	etivos	5
2	FU	NDA	MENTAÇÃO TEÓRICA	7
	2.1	Mis	são EO-1 e sensor Hyperion	7
	2.2	Atri	butos hiperespectrais	9
	2.3	Sele	ção de atributos por meio do aplicativo WEKA	14
	2.4	Algo	pritmos de classificação	16
	2	.4.1	Spectral Angle Mapper (SAM)	17
	2	.4.2	Support Vector Machine (SVM)	18
	2	.4.3	Árvore de decisão J48 (AD)	21
	2	.4.4	Random Forest (RF)	23
	2.5	Sim	ulação estocástica	25
3	ÁR	EA D	E ESTUDO	27
4	ME	TOD	OLOGIA	35
	4.1	Sele	ção da área de estudo e das imagens Hyperion/EO-1	35
	4.2	Pré-	processamento das imagens Hyperion/EO-1	
	4.3	Extr	ação dos atributos hiperespectrais	
	4.4	Cara	acterização espectro-temporal	41
	4.5	Sele	ção de atributos	41
	4.6	Clas	sificação das fitofisionomias do PNB	42
	4	.6.1	Análise de incerteza das classificações	45
	4.7	Ava	liação das classificações por meio de simulação estocástica	46
5	RE	SUL	TADOS E DISCUSSÃO	49
	5.1	Cara	acterização sazonal da resposta espectral das fitofisionomias do PNB	49
	5	.1.1	Influência da geometria de aquisição de dados	49
	5	.1.2	Variação sazonal dos atributos hiperespectrais	52
		5.1.2	2.1 Reflectância	52
		5.1.2	2.2 Derivada de 1 <sup>ª</sup> ordem	53
		5.1.2	2.3 Índices de vegetação	54
		5.1.2	2.4 Parâmetros de bandas de absorção	58
	5.2	Sele	ção de atributos e classificação supervisionada após seleção	59

# SUMÁRIO

5.2.1	Seleção de atributos usando CFS	59
5.2.2	Avaliação de desempenho das classificações nos períodos chuvoso e seco	62
5.2.3	Quantificação das incertezas por meio da entropia de Shannon	76
5.3 An	álise estatística por meio de técnicas de simulação estocástica	79
6 CONCI	LUSÃO	87
REFERÊNCIAS BIBLIOGRÁFICAS9		91
APÊNDICE A – MATRIZES DE CONFUSÃO EM RELAÇÃO AOS ATRIBUTOS HIPERESPECTRAIS		

### 1 INTRODUÇÃO

O Cerrado é um importante bioma brasileiro, considerado um dos *hotspots* mundiais de maior biodiversidade (MYERS et al., 2000). A sazonalidade é um fator determinante para o desenvolvimento da vegetação desse ecossistema, que desempenha importante papel para os balanços energético e hídrico do Brasil. O Cerrado atua ainda como sumidouro de gases do efeito estufa, já que há um estoque de carbono mais expressivo nas fitofisionomias arbóreas e na biomassa subterrânea desse ambiente (BUSTAMANTE; OLIVEIRA, 2008; FERREIRA, 2003a).

A vegetação do Cerrado é composta por grande diversidade de espécies vasculares, estruturadas em hábitos herbáceo, arbustivo e arbóreo. Apesar da importância desse ecossistema, dados governamentais apontam que pouco mais que 5% de toda a área do Cerrado encontram-se protegida na forma de Unidades de Conservação. Dentre essas, destaca-se o Parque Nacional de Brasília (PNB), que possibilita o abrigo de inúmeras espécies representativas da fauna e da flora do ecossistema Cerrado, além da manutenção de importantes mananciais hídricos (FERREIRA, 2003a).

O PNB é considerado um importante berço para o abrigo de espécies vegetais nativas do Cerrado. Contudo, há também a presença de espécies vegetais exóticas invasoras, as quais representam um dos maiores problemas de manejo para a Unidade de Conservação. No PNB há registros de espécies exóticas arbóreas, arbustivas e herbáceas, sendo que o grupo das gramíneas se destaca pelo seu rápido estabelecimento e dominância sobre a vegetação nativa. Dentre as espécies de gramíneas exóticas encontradas no PNB destacam-se *Melinis minutifolia* (capim-gordura), *Urochloa decumbens* (braquiária), *Andropogon gayamus* e *Hyparrhenia rufa* (jaraguá) (MARTINS et al., 2007). Devido à ocorrência de diversas fitofisionomias, o PNB tem sido utilizado como uma espécie de laboratório ou área-teste para diversos tipos de estudos no Cerrado.

Tendo em vista a importância do levantamento e do mapeamento das fitofisionomias desse ecossistema, o sensoriamento remoto tornou-se uma ferramenta essencial para o imageamento de grandes áreas em um curto espaço de tempo. Diante da necessidade

de conservação e de proteção do ecossistema Cerrado, o sensoriamento remoto hiperespectral tem se destacado recentemente por proporcionar maior detalhamento das características biofísicas e bioquímicas da vegetação. Diante da perspectiva de lançamento de novos satélites transportando sensores de alta resolução espectral, adquirindo imagens em faixas mais amplas do terreno, estudos hiperespectrais no Cerrado têm se tornado necessários e cada vez mais importantes. As características espectrais da vegetação são observadas por sensores hiperespectrais através da análise de um espectro de reflectância contínuo para cada *pixel* da cena, formado a partir de centenas de bandas estreitas e contíguas do sensor (GALVÃO et al., 2012).

As centenas de bandas dos sensores hiperespectrais possibilitam a extração de atributos e de métricas, os quais podem ser utilizados para a análise espectral da vegetação. Dentre esses, destacam-se reflectância, derivada de 1<sup>a</sup> ordem, parâmetros de bandas de absorção e índices de vegetação (IVs) de bandas estreitas. Tais atributos são importantes para a compreensão do gradiente de vegetação no bioma Cerrado, já que confusões espectrais entre classes fitofisionômicas são comumente observadas. Um exemplo de difícil diferenciação ocorre para as formações Campo Sujo e Campo Limpo, assim como para Campo Cerrado e Cerrado *sensu stricto* (FERREIRA, 2003a).

A discriminação de fitofisionomias do Cerrado pode ser feita por meio da utilização de classificadores supervisionados. Esses classificadores levam em consideração um conjunto de amostras conhecidas, selecionadas pelo usuário, para calibrar o algoritmo de classificação. A escolha dos algoritmos de classificação *Spectral Angle Mapper* (SAM), *Support Vector Machine* (SVM), Árvore de Decisão J48 (AD) e *Random Forest* (RF), utilizados neste estudo, deve-se à capacidade desses algoritmos em suportar o grande volume de dados hiperespectrais, além das diferentes estratégias proporcionadas para sua exploração.

Uma forma de avaliar as incertezas das classificações pode se dar por meio da avaliação da entropia dos mapas classificados. Outra maneira de avaliar as incertezas consiste na utilização de técnicas de simulação estocástica, que proporcionam resultados estatísticos mais robustos. Essas técnicas amostram, aleatoriamente, um subconjunto dos dados de entrada de modo a simular, por meio de *n* repetições, os parâmetros estatísticos da Função de Distribuição de Probabilidade (FDP) para determinada variável.

Alguns trabalhos foram publicados na literatura a respeito da discriminação de fitofisionomias no Cerrado usando dados ópticos e de radar. Dentre eles, pode-se destacar os trabalhos de Sano et al. (2001); Ferreira et al. (2003a); Ferreira (2003b); Miura et al. (2003); Sano et al. (2005); Liesenberg et al. (2007); Souza et al. (2010), Ferreira et al. (2011) e Jacon et al. (2017). Dentre esses, os artigos de Miura et al. (2003), Ferreira et al. (2011) e Jacon et al. (2017) envolveram algum tipo de dado hiperespectral no estudo da vegetação. Contudo, a utilização de dados orbitais hiperespectrais ainda é pouco explorada para o ecossistema Cerrado, devido à indisponibilidade periódica de imagens para a composição de séries temporais.

Nesse contexto, o sensor Hyperion/*Earth Observing One* (EO-1) foi lançado em 21 de novembro de 2000 como teste de tecnologia para o monitoramento da Terra, tornandose um importante instrumento utilizado pela comunidade científica para a obtenção de dados hiperespectrais da superfície terrestre. O sensor Hyperion, composto por 242 bandas espectrais, operou sob o sistema de varredura "*pushbroom*", fornecendo imagens com 30 metros de resolução espacial e 10 nm de resolução espectral. O tempo de revisita do sensor era de 16 dias, sendo possível a obtenção de imagens off-nadir em um espaço de tempo menor. O papel do sensor, ao fornecer dados que possibilitam o cálculo de estimativas sobre parâmetros biofísicos e bioquímicos da vegetação, despertou o interesse científico para o desenvolvimento e lançamento de outros sensores hiperespectrais, visando à aquisição de dados orbitais de alta qualidade radiométrica.

Dentre as missões planejadas para os próximos anos, destacam-se os satélites EnMAP (*Environmental Mapping and Analysis*) e HyspIRI (*Hyperspectral Infrared Imager*). Tais sensores hiperespectrais apresentam ampla faixa de imageamento e melhor relação sinal/ruído, quando comparado às especificações do sensor Hyperion. A

missão EnMAP reuniu um grupo de pesquisadores em seu denominado *EnMAP Scientific Advisory Group* (EnSAG), que definiram como uma de suas prioridades no Brasil o mapeamento e o monitoramento das fitofisionomias do Cerrado, já que este é considerado um dos *hotspots* mundiais de maior biodiversidade.

Os dados EnMAP serão coletados numa faixa de imageamento de 30 km, com resolução espacial de 30 m e relação sinal/ruído de 500:1 para a faixa do visível e infravermelho próximo (VNIR) e 150:1 para a faixa do infravermelho de ondas curtas (SWIR) (GUANTER et al., 2015). Seu lançamento está previsto para o ano de 2019. Já o HyspIRI, com previsão de lançamento ainda incerta, coletará dados numa faixa de imageamento de 150 km no VNIR e SWIR, com resolução espacial de 30 m ao nadir e relação sinal/ruído de 600:1 no VNIR e 300:1 no SWIR (HOCHBERG et al., 2015).

Considerando a perspectiva dessa nova geração de satélites hiperespectrais, o sensor Hyperion, com um conjunto restrito de imagens adquiridas entre 2000 e 2016 sob demanda no Brasil, ainda constitui uma valiosa base de dados para antecipar aplicações potenciais desses novos sensores. Uma das áreas imageadas pelo Hyperion foi o PNB, resultando em trabalhos como o de Miura et al. (2003). Nesse estudo, os autores utilizaram uma abordagem que incluía a aplicação de modelo de mistura espectral na região do SWIR, verificando o potencial do sensoriamento remoto hiperespectral para a caracterização biofísica da vegetação, bem como para a discriminação de fitofisionomias do Cerrado.

Conforme destacado por Jacon et al. (2017), a caracterização sazonal e a discriminação de fitofisionomias do cerrado ainda constituem um desafio devido à alta variabilidade espacial da cobertura vegetal e à similaridade espectral de algumas fitofisionomias. A utilização de diferentes classificadores supervisionados com distintos atributos hiperespectrais, testados nas estações chuvosa e seca do Cerrado, pode ser útil nesse sentido.

### 1.1 Hipótese de trabalho

Considerando as diferentes características estruturais e fisiológicas da vegetação diante da sazonalidade do Cerrado, testa-se a hipótese que o uso combinado de diferentes atributos hiperespectrais do sensor Hyperion/EO-1 contribui para o melhor desempenho de algoritmos de classificação na discriminação de fitofisionomias do Cerrado.

#### 1.2 Objetivos

O objetivo deste trabalho consiste em identificar o melhor conjunto de atributos hiperespectrais do sensor Hyperion/EO-1, avaliando o desempenho de diferentes técnicas de classificação supervisionadas com esses atributos para discriminação de fitofisionomias do Cerrado no PNB nos períodos chuvoso e seco.

Os seguintes objetivos específicos foram propostos:

- Caracterizar a resposta sazonal das fitofisionomias do PNB por meio dos atributos hiperespectrais do sensor Hyperion/EO-1;
- Selecionar os atributos hiperespectrais com maior capacidade de discriminação das fitofisionomias, nos períodos chuvoso e seco, e utilizá-los em algoritmos de classificação, analisando as incertezas por meio da entropia de Shannon.
- Utilizar técnicas de simulação estocástica para avaliação estatística das classificações nos períodos chuvoso e seco.

## 2 FUNDAMENTAÇÃO TEÓRICA

#### 2.1 Missão EO-1 e sensor Hyperion

A missão *Earth Observing One* – 1 (EO-1), do Programa Novo Milênio da NASA, foi concebida para dar continuidade à tecnologia do satélite Landsat-7. A missão foi voltada para o desenvolvimento de tecnologias espaciais que permitissem a redução direta dos custos de sistemas de monitoramento da Terra (LANDIS et al., 2016).

A missão EO-1 foi planejada para atuar durante o período de um ano (2000 a 2001) sob órbita polar descendente de norte a sul, com passagem pela linha do Equador às dez horas da manhã. A configuração de passagem foi próxima à passagem dos satélites Landsat-7 e Terra (LANDIS et al., 2016).

Pelas boas condições que a plataforma apresentava foi decidido em 2007 que a missão EO-1 deveria continuar em operação mesmo após a extrapolação do tempo de vida útil do satélite. Em 2011, no entanto, com limitações para retornar à sua órbita de origem, foi permitido que o instrumento passasse a operar sob deriva da gravidade ocasionando, por conseguinte, lento decaimento do tempo local médio de passagem do satélite pela linha do Equador.

A realização desse experimento inédito teve como finalidade analisar como órbitas mais baixas e horários incomuns de imageamento (decaindo de 10:00 h até 8:00 h) poderiam afetar a utilidade dos dados da imagem (LANDIS et al., 2016). A missão durou até setembro de 2016 quando o horário local médio de passagem do satélite pelo Equador ocorreu às oito horas da manhã.

Composta por três principais instrumentos de imageamento, a plataforma EO-1 comportou, além do sensor multiespectral ALI (*Advanced Land Imager*) e do sensor LAC (*Linear etalon imaging spectrometer array Atmospheric Corrector*), o sensor hiperespectral Hyperion. Ainda que designado para operar como sensor teste, a gama de aplicabilidades do Hyperion/EO-1 é notável, uma vez que é citado em mais de 450 publicações científicas na base ISI da *Web of Science*.

O Hyperion/EO-1 foi o primeiro sensor hiperespectral orbital a imagear a Terra com resolução espacial de 30 m e resolução espectral de 10 nm. Demonstrou a ampla capacidade dos sensores hiperespectrais orbitais em identificar e em mapear espécies da vegetação, inclusive invasoras; a estimar concentrações de nitrogênio em dosséis; e a mapear com alta exatidão classes de vegetação propícias à ocorrência de fogo (LANDIS et al., 2016).

Durante sua atuação, o Hyperion/EO-1 operou sob o sistema de varredura "*pushbroom*", resultando em imagens com faixa de imageamento de 7,5 km (*cross-track*) por 60 km *along-track* (THENKABAIL et al., 2012). O sensor era constituído por dois espectrômetros de imageamento nas faixas do VNIR e SWIR (FOLKMAN et al., 2001). Com resolução espacial de 30 m, os dados de radiância eram obtidos a uma altitude de 705 km, sob inclinação de 98,2°. De um total de 242 bandas contíguas, apenas 196 bandas apresentavam-se calibradas radiometricamente entre o intervalo de 426 nm e 2395 nm (GALVÃO et al., 2009a).

A resolução temporal de 16 dias ou o tempo de revista de cena pode ser otimizado por apontamento do sensor ou visada lateral (PEARLMAN et al., 2003). No entanto, a visada off-nadir resultante pode apresentar significativos efeitos direcionais sobre a resposta espectral da vegetação. Tais efeitos decorrem da característica anisotrópica da vegetação, a qual é influenciada por mudanças na geometria de observação do sensor e de iluminação do alvo (GALVÃO et al., 2009b; PONZONI et al., 2010).

A baixa relação sinal-ruído do sensor, sobretudo na região espectral do SWIR, é capaz de comprometer a mensuração precisa de feições espectrais ao longo do espectro de reflectância (GALVÃO et al., 2009b). Apesar disso, o Hyperion/EO-1 foi considerado pela comunidade científica um importante instrumento capaz de fornecer estimativas sobre propriedades biofísicas e bioquímicas da vegetação, além de outras aplicabilidades.

Exemplos da utilização do sensor Hyperion/EO-1 incluem estudos para avaliar a relação entre índices de vegetação de bandas estreitas, parâmetros biofísicos e dados de elevação no ambiente de Cerrado (SOUZA et al., 2010); estimativa do conteúdo de

água em dosséis de Cerrado (FERREIRA et al., 2011); estudo de anisotropia da vegetação por meio de índices hiperespectrais (GALVÃO et al., 2013); mapeamento da cobertura de resíduos em culturas (BANNARI et al., 2015); e caracterização sazonal e discriminação de fitofisionomias do Cerrado por meio de métricas hiperespectrais (JACON et al., 2017).

### 2.2 Atributos hiperespectrais

A extração de atributos hiperespectrais é uma forma de caracterizar e representar a estrutura e a fisiologia da vegetação. Tais atributos podem estar associados tanto à estrutura e ao conteúdo de água nas folhas, os quais são observáveis na faixa do NIR, quanto à presença de elementos químicos como lignina, celulose e nitrogênio, que se manifestam na região espectral do SWIR (CLARK; ROBERTS, 2012).

A reflectância permite a caracterização espectral da vegetação em diferentes níveis de coleta de dados. Sob a escala foliar, a reflectância é influenciada tanto pelos elementos bioquímicos da folha (conteúdo de água, pigmentos fotossintéticos e carboidratos), quanto pelas características morfológicas (espessura da parede celular, espaços de ar e ceras na cutícula) que exercem influência sobre o espalhamento dos fótons (ASNER, 1998). Já sob o aspecto orbital da vegetação, a arquitetura tridimensional do arranjo foliar e de componentes não fotossintéticos determinam a quantidade de espalhamento volumétrico dos fótons e a atenuação dentro do dossel (ASNER, 1998; CLARK et al., 2005).

Tratando-se da reflectância espectral de dosséis, Goel (1988) definiu a fonte de radiação como um importante subsistema pertencente ao sensoriamento remoto da vegetação. A fonte de radiação, comumente representada pelo Sol, pode ser definida por uma série de parâmetros, dentre os quais destacam-se a irradiância espectral e a geometria de iluminação.

Os ângulos zenital ( $\theta$ s) e azimutal ( $\varphi$ s) solar, em conjunto, definem a posição do Sol. Esses são controlados por ciclos da dinâmica anual, dado pela declinação solar, e por ciclos diurnos, por meio do ângulo horário (VALERIANO, 2011). Enquanto o ângulo azimutal solar assume valores entre  $0^{\circ}$  e 360°, o ângulo zenital se restringe entre  $0^{\circ}$  e 90° graus.

Considera-se a latitude como fator determinante para a análise dos ângulos zenital e azimutal solar. Para o ângulo azimutal solar, por exemplo, o sinal da diferença entre declinação e latitude define o sentido horário ou anti-horário do movimento azimutal aparente do Sol (VALERIANO, 2011). Para o ângulo zenital solar, as variações angulares são mais perceptíveis para altas latitudes.

Além da reflectância de bandas, outra técnica de espectroscopia consiste na análise de derivada dos espectros. Segundo Tsai e Philpot (1998), essa técnica é particularmente propícia para a aplicação em dados de sensoriamento remoto hiperespectral. Esse atributo proporciona informações hiperespectrais adicionais associadas à estrutura e química da vegetação (CLARK; ROBERTS, 2012).

Conceitualmente a aplicação de derivada sobre uma função representa uma forma de quantificar a taxa de variação de uma determinada variável em relação à outra. No caso de um espectro, representa a taxa de variação de reflectância espectral em relação à variação do comprimento de onda da energia incidente (BARBOSA, 2005). Nota-se, no entanto, que as análises espectrais por derivadas são notoriamente sensíveis a ruídos, sendo recomendada, portanto, a utilização de filtros.

Uma alternativa simples para a obtenção da derivada de primeira ordem dá-se por meio de uma aproximação por diferença finita. A Equação 2.1 mostra como pode ser estimada a primeira derivada de uma curva espectral (TSAI; PHILPOT, 1998):

$$\frac{dy}{dx}\Big| i \approx \frac{s(\lambda_i) - s(\lambda_j)}{\Delta \lambda}$$
(2.1)

Em que  $\Delta\lambda$  é a separação entre as bandas adjacentes, sendo  $\lambda_j > \lambda_i$ , com intervalo constante entre as bandas;  $s(\lambda_i)$  e  $s(\lambda_j)$  são valores do espectro na faixa dos comprimentos de onda  $\lambda_i$  e  $\lambda_j$ , respectivamente.

O atributo derivada de 1<sup>a</sup> ordem permite ainda determinar a posição do ponto de máxima inflexão que ocorre pela rápida transição entre a região espectral do vermelho e do infravermelho próximo (*Red Edge*). A Posição do *Red Edge* (REP) é diretamente associada ao conteúdo de clorofila foliar, podendo ser considerada um indicador de estresse da vegetação (GITELSON et al., 1996; QI et al., 2011).

Os Índices de Vegetação (IVs) são métricas utilizadas para estimar as propriedades biofísicas e bioquímicas da vegetação. Sua aplicação pode envolver tanto bandas largas quanto bandas estreitas. No entanto, duas principais limitações estão associadas aos sensores de bandas largas: a saturação dos IVs para vegetação densa (JIANG; HUETE, 2010), em que para IAF acima de 3, ou quantidade de biomassa elevada, alguns desses índices tornam-se assintóticos; e a limitação na formulação da maioria dos IVs a partir de medidas espectrais apenas nas bandas do vermelho e do NIR (THENKABAIL et al., 2012). Por outro lado, os IVs de bandas estreitas apresentam grande dinamicidade de formulação ao longo das bandas do espectro, resultando em melhores modelagens de propriedades biofísicas e bioquímicas da vegetação.

Outra vantagem para o uso de IVs de bandas estreitas consiste na oportunidade de encontrar um indicador direto para o estudo de uma variável da vegetação. Como exemplo, tem-se a utilização de índices envolvendo o comprimento de onda em 980 nm para detectar a sensibilidade à umidade; índices de estresse, envolvendo a região do *Red Edge* ao redor 720 nm; e a estimação de deficiência de nitrogênio, utilizando a banda em 1316 nm (THENKABAIL et al., 2012).

A análise espectral da vegetação pode ainda ser realizada por meio de parâmetros associados às feições de absorção no espectro, as quais são definidas pela presença de elementos químicos. Como exemplo, têm-se as folhas verdes fotossintéticas, com predominância de clorofila a e b e pigmentos acessórios (carotenoides), os quais dominam as feições de absorção do espectro na faixa do VIS (680 nm) (USTIN et al., 2009). A presença de água nas folhas induz, por sua vez, a formação de feições de absorção na faixa do NIR em 980 nm e 1200 nm, respectivamente (GAO; GOETZ, 1990). Para a faixa do SWIR há relativamente baixa reflectância e forte absorção pela

água em folhas verdes. Essa absorção frequentemente mascara feições de absorção por outros constituintes químicos, dentre elas a absorção por lignina e celulose nas bandas posicionadas em 1700 nm, 2100 nm e 2300 nm, as quais podem ser mais bem notadas quando os tecidos das plantas encontram-se secos (CURRAN, 1989; KOKALY et al., 2009).

A discriminação espectral pode ser influenciada pelas diferenças químicas e estruturais da vegetação, as quais proporcionam diferentes feições de absorção entre as regiões do VIS e do SWIR (CLARK; ROBERTS, 2012). Uma técnica associada à determinação das características de feições de absorção é a remoção do contínuo (CLARK; ROUSH, 1984), expressa pela Equação 2.2 e representada na Figura 2.1b. O contínuo consiste numa função matemática utilizada para isolar bandas de absorção particulares dos espectros de reflectância (BREUNIG et al., 2007), permitindo um melhor detalhamento das feições de absorção a partir da normalização do espectro.

$$\rho_{CR\lambda} = \frac{\rho_{original \lambda}}{\rho_{contínuo \lambda}}$$
(2.2)

Onde  $\rho_{CR\lambda}$  é o fator de reflectância direcional cônico com o contínuo removido;  $\rho_{original \lambda}$  é o fator de reflectância direcional cônico original; e  $\rho_{contínuo \lambda}$  é o espectro do contínuo. O  $\lambda$  representa o comprimento de onda.

O espectro do contínuo pode ser formulado matematicamente pela equação da reta, cujo coeficiente angular (k) é definido pela Equação 2.3 e o coeficiente linear (w) é obtido por meio da Equação 2.4, ajustada aos limites superiores e inferiores de cada banda de absorção.

$$k = \frac{y_2 - y_1}{\lambda_2 - \lambda_1} \tag{2.3}$$

$$w = \frac{[y_1.(\lambda_2 - \lambda_1)] + [-\lambda_1.(y_2 - y_1)]}{\lambda_2 - \lambda_1}$$
(2.4)
Onde  $y_2$  representa  $\rho$  observado no limite superior da banda;  $y_1$  representa  $\rho$  observado no limite inferior da banda;  $\lambda_2$  representa o comprimento de onda do limite superior; e  $\lambda_1$  o comprimento de onda do limite inferior.

O parâmetro profundidade de banda ( $B_d$ ) pode ser obtido por meio da Equação 2.5 (KOKALY; CLARK, 1999), e está ilustrado na Figura 2.1c.

$$B_d = (1 - \rho_{CR\lambda}) \tag{2.5}$$

Nota-se que  $\rho_{CR\lambda}$  é o fator de reflectância direcional cônico com a remoção do contínuo, obtida pela Equação 2. A largura da banda de absorção é obtida pela largura dessa banda na posição de meia altura da profundidade máxima (FWHM) (KRUSE et al., 1993a).

Pela equação 2.6, nota-se que a área da banda de absorção ( $A_B$ ) pode ser calculada através da aproximação numérica que considera a área de um trapézio entre cada  $\lambda$  discretizado pelo sensor para os limites apresentados (MEER, 2004). A área da banda de absorção está representada pela Figura 2.1d.

$$A_{B} = \sum_{i=m}^{M} \frac{(\rho_{i} + \rho_{i-1})}{2} . (\lambda_{i} - \lambda_{i-1})$$
(2.6)

Onde *i* representa o passo de cálculo (função da capacidade do sensor de discriminar o sinal) que vai de *m*, limite inferior da banda a *M*, limite superior da banda.

A assimetria de feições de absorção representa o logaritmo da razão entre a área à direita da posição do comprimento de onda de máxima absorção e a área à esquerda (Equação 2.7). O resultado do cálculo será zero se a feição de absorção se apresentar perfeitamente simétrica, negativo se a feição de absorção estiver enviesada para os comprimentos de onda mais curtos e positiva se a feição estiver enviesada para os comprimentos de onda mais longos (KRUSE et al., 1993a; ZAINI et al., 2012).



Figura 2.1 Banda de absorção sem a remoção do contínuo (a) e com o contínuo removido (b); e parâmetros de bandas de absorção profundidade e largura (c) e área (d).

Fonte: Kokaly e Skidmore (2015).

# 2.3 Seleção de atributos por meio do aplicativo WEKA

A mineração de dados consiste num processo de extração de padrões de feições conhecidas, que são utilizados na predição de outras feições mediante a aplicação de algoritmos específicos. Nesse contexto, o aplicativo de código aberto *Waikato Environment for Knowledge Analysis* (WEKA) (HALL et al., 2009), composto por uma coleção de algoritmos de aprendizagem, tem sido amplamente utilizado.

Uma etapa essencial à mineração de dados consiste na seleção de atributos, a qual exerce importante função na identificação e na remoção de características irrelevantes ou redundantes do conjunto de dados original. A remoção de tais características proporciona a redução no tempo de execução de algoritmos de aprendizagem para o reconhecimento de padrões, além de contribuir para a predição de acurácia no processo de classificação (DASH; LIU, 1997).

Sensores hiperespectrais como o Hyperion/EO-1 adquirem dados em centenas de bandas espectrais, as quais apresentam alta correlação entre si, resultando em medidas redundantes. Portanto, um ótimo subconjunto de dados pode ser definido como aquele que contém atributos altamente correlacionados às classes de interesse e descorrelacionados entre si (HALL, 1999).

Diante disso, o algoritmo de seleção de atributos *Correlation based Feature Selection* (CFS) (HALL, 1999) distingue-se por proporcionar a seleção de um subconjunto de dados que aborde tais características. O CFS é um algoritmo categorizado como *filter*, o qual avalia o grau de importância do subconjunto de atributos, baseado numa função de avaliação heurística.

O algoritmo CFS utiliza uma função de avaliação enviesada para subconjuntos com atributos altamente correlacionados às classes (mérito) e descorrelacionados entre si. Dessa forma, quanto maior a correlação do atributo à classe, maior será o mérito. A Equação 2.8 expressa a função de avaliação do subconjunto de atributos pelo método CFS, em que o mérito é calculado com base no coeficiente de correlação de Pearson, onde todas as variáveis encontram-se padronizadas:

$$M_S = \frac{kr_{\overline{cf}}}{\sqrt{k+k(k-1)r_{\overline{ff}}}}$$
(2.8)

Onde  $M_s$  é o mérito do subconjunto *S* contendo *k* atributos,  $r_{cf}$  é a correlação média entre classe e atributo, e  $r_{ff}$  representa a correlação média entre os atributos. Enquanto o numerador avalia quão preditivo é o conjunto de atributos em relação à determinada classe, o denominador indica quanto de redundância há entre os atributos escolhidos. O algoritmo de seleção CFS atua sobre o conjunto original de dados, não exigindo qualquer tipo de transformação, e assume que os atributos se comportam de forma independente para cada classe. Isso possibilita, portanto, a avaliação do desempenho de um subconjunto de atributos considerando a habilidade de predição individual de cada um, levando ainda em consideração o grau de redundância existente entre eles.

### 2.4 Algoritmos de classificação

A utilização de bandas estreitas para a classificação da vegetação pode proporcionar exatidão substancialmente superior àquela obtida por meio dos sensores multiespectrais de bandas largas (THENKABAIL et al., 2004a). No entanto, para um número elevado de bandas dos sensores hiperespectrais, o número de *pixels* de treinamento necessários cresce exponencialmente, tornando-se muito difícil a abordagem dessa diversidade espectral (THENKABAIL et al., 2012).

Esse fenômeno, conhecido como efeito *Hughes*, pode ocasionar a perda de exatidão quando a dimensionalidade dos dados aumenta, enquanto que o tamanho das amostras de treinamento permanece constante (HUGHES, 1968). O efeito causado pela alta dimensionalidade dos dados hiperespectrais pode ser minimizado através do processo de seleção de atributos.

O estudo de Breunig et al. (2011) demonstrou que a exatidão de classificação de dados hiperespectrais utilizando o algoritmo *Support Vector Machine* (SVM) decresce com a inclusão de bandas adicionais na análise. Tal comportamento também foi notado no trabalho de Pal e Foody (2010), os quais recomendaram a etapa prévia de seleção de atributos. Já a classificação *Random Forest* (RF) caracteriza-se por ser relativamente insensível ao efeito *Hughes* sendo, portanto, indiferente ao número de amostras utilizadas para treinamento em relação ao espaço dimensional de atributos (IMMITZER et al., 2012). Mesmo neste caso, no entanto, a seleção de atributos é interessante para eliminar variáveis ou informação redundante e facilitar a interpretação dos resultados.

Dentre as características dos algoritmos de classificação explorados neste estudo estão: a abordagem através da forma do espectro, proporcionada pelo *Spectral Angle Mapper* (SAM); uma excelente capacidade de generalização e de reconhecimento de padrões proporcionado pelo SVM; a flexibilidade e a robustez da árvore de decisão em relação a não-linearidade dos dados; além de um sistema de votação de classes através do algoritmo *Random Forest*.

### 2.4.1 Spectral Angle Mapper (SAM)

O algoritmo *Spectral Angle Mapper* (SAM) (KRUSE et al., 1993) determina a similaridade espectral entre dois espectros por meio do cálculo do ângulo espectral formado entre eles. Assim, o espectro de um *pixel* qualquer é comparado a um espectro de referência, o qual pode ser mensurado em campo ou extraído da própria imagem. Para fins de comparação, os espectros são representados na forma de vetores, num espaço *n*-dimensional, onde *n* representa o número de bandas espectrais (KRUSE et al., 1993b).

O SAM é um método de classificação que não sofre influência de fatores de iluminação solar porque o ângulo formado entre os dois vetores é independente do comprimento do vetor (KRUSE et al., 1993b). O valor SAM é expresso em radianos, em que o menor ângulo  $\alpha$  (0° a 90°) formado indica alta similaridade, enquanto que o maior ângulo representa baixa similaridade entre os espectros. Pela Equação 2.9 podese encontrar o valor de cos  $\alpha$ , sendo a melhor estimativa expressa com valor próximo a 1, que representa alta similaridade entre os espectros.

$$\cos \alpha = \frac{\sum XY}{\sqrt{\sum (X)^2 \sum (Y)^2}}$$
(2.9)

Onde  $\alpha$  é o ângulo formado entre o espectro de referência e o espectro da imagem; *X* é o espectro da imagem e *Y* é o espectro de referência.

Além de permitir rápido mapeamento da similaridade espectral, o algoritmo apresentase como um importante método de classificação que desconsidera a influência dos efeitos de sombra, visando acentuar as características de reflectância dos alvos (CARVALHO, et al., 2000). Outra vantagem do SAM, em relação aos dados de imagens hiperespectrais, é o fato de que a atuação do algoritmo melhora com a dimensão crescente do vetor, que se dá por meio do acréscimo do número de bandas espectrais (CLARK et al., 2005).

A principal desvantagem desse método está associada à mistura espectral, decorrente da complexidade e da heterogeneidade da superfície terrestre. Uma vez que o SAM utiliza como referência espectros de *pixels* para fins de comparação e de classificação, esses *pixels* podem não ser representantes fieis dos alvos, sobretudo em relação a imagens de média resolução espacial (GIROUARD et al., 2004). A confusão espectral, portanto, pode ocasionar erros de subestimação e de superestimação na determinação das classes espectrais. Além disso, espectros de materiais claros e escuros (diferentes brilhos) podem ser erroneamente classificados como similares, dependendo da forma de seus espectros, o que constitui um erro grosseiro de classificação. As chances de isso ocorrer aumentam com a redução do número de bandas na classificação SAM.

#### 2.4.2 Support Vector Machine (SVM)

Desenvolvido por Cortes e Vapnik (1995), o *Support Vector Machine* (SVM) é um algoritmo de classificação não paramétrico, que leva em consideração a teoria estatística em seu processo de aprendizagem para o reconhecimento de padrões. Sua alta capacidade de generalização permite a construção de uma superfície de decisão linear, mesmo para os vetores pertencentes a um espaço de atributos altamente dimensional, os quais são adicionados por algum procedimento não linear (CORTES; VAPNIK, 1995).

O SVM baseia-se na teoria do princípio de separação ótima entre classes, na qual é utilizado um hiperplano ótimo. O hiperplano é definido como uma função de decisão linear que apresenta uma margem de maior separação entre os vetores de duas classes. A Figura 2.2 ilustra a disposição das amostras mais representativas de cada classe, as quais definem as margens do hiperplano, sendo essas denominadas vetores suporte (CORTES; VAPNIK, 1995).

Figura 2.2. Hiperplano e vetores suporte definindo as margens máximas entre duas classes linearmente separáveis.



Fonte: Adaptado de Fletcher (2009).

Segundo Cortes e Vapnik (1995), um hiperplano no espaço de atributos é definido por:

$$w_0 \cdot z + b_0 = 0 \tag{2.10}$$

Onde  $w_0$  é o peso considerado para o hiperplano no espaço de atributos, podendo ser escrito como uma combinação linear dos vetores suporte:

$$w_0 = \sum_{vetores \, suporte} \alpha_i z_i \tag{2.11}$$

Sendo assim, a função de decisão linear  $I_{(z)}$  no espaço de atributos será:

$$I_{(z)} = sinal\left(\sum_{vetores \ suporte} \alpha_i z_i \,.\, z + b_0\right)$$
(2.12)

Onde  $z_i$ . z é o produto escalar entre os vetores suporte  $z_i$  e o vetor z no espaço de atributos.

Para a definição de um hiperplano ótimo considera-se um conjunto de treinamento

$$(y_1, x_1), \dots, (y_l, x_l), \quad y_i \in \{-1, 1\},$$
 (2.13)

em que este pode ser dito linearmente separável se existe um vetor w e um escalar b, tal que as desigualdades

$$w \cdot x_i + b \ge 1 \qquad \text{se } y_i = 1 \tag{2.14}$$

$$w \cdot x_i + b \leq -1 \qquad se y_i = -1$$

sejam válidas para todos os elementos do conjunto de treinamento (2.13). As desigualdades (2.14) podem ser reescritas na forma:

$$y_i(w, x_i + b) \ge 1$$
  $i = 1, ..., l$  (2.15)

Sendo o hiperplano o único que separa os dados de treinamento com uma margem máxima, é possível determinar a direção w/|w| onde a distância entre a projeção dos vetores de treinamento de duas classes diferentes é máxima. Essa distância pode ser representada por:

$$\rho(w,b) = \min_{\{x:y=1\}} \frac{x.w}{|w|} - \max_{\{x:y=-1\}} \frac{x.w}{|w|}$$
(2.16)

Portanto, o hiperplano ótimo  $(w_0, b_0)$  é o argumento que maximiza a distância (2.16). Assim, a partir de (2.15) e (2.16) temos que:

$$\rho(w_0, b_0) = \frac{2}{|w_0|} = \frac{2}{\sqrt{w_0 \cdot w_0}}$$
(2.17)

A finalidade do SVM consiste em obter um equilíbrio entre os erros obtidos na etapa de treinamento e os erros referentes ao conjunto teste (MOUNTRAKIS et al., 2011). Assim, o algoritmo busca minimizar o excesso de ajustes em relação às amostras de treinamento, bem como melhorar a capacidade de generalização e reconhecimento de padrões (VAPNIK, 1995).

O SVM destaca-se por apresentar um desempenho satisfatório diante de pequenos conjuntos de amostras de treinamento (GÓMEZ et al., 2016). Contudo, dentre as desvantagens, destacam-se o elevado custo computacional exigido pelo algoritmo e também o seu baixo desempenho diante de pequenos espaços de atributos.

# 2.4.3 Árvore de decisão J48 (AD)

Na abordagem por árvore de decisão, as regras de classificação são exploradas a partir da subdivisão do conjunto de dados, proporcionando um fácil entendimento ao usuário quanto a sua implementação (ONIK et al., 2015). Os algoritmos que compõem as árvores de decisão são estritamente não-paramétricos e, portanto, não fazem pressupostos a respeito da distribuição dos dados de entrada. Caracterizam-se por serem flexíveis e robustos em relação a não linearidade dos dados e também em relação a eventuais ruídos (FRIEDL; BRODLEY, 1997).

As árvores são formadas por um nó raiz e por nós subsequentes. Cada um desses nós contém um teste sobre um atributo de forma que os resultados formam os ramos da árvore. Os algoritmos construtores das árvores de decisão buscam aqueles atributos e valores que fornecem máxima discriminação dos dados, a cada nível da árvore, de acordo com o atributo que se queira classificar. A raiz inicial e os nós subsequentes têm por finalidade conduzir a escolha de uma decisão final. Essa decisão é aceita baseada em um conjunto de regras em que se a condição existe então a inferência é aplicada.

Baseadas em eficientes técnicas de mineração de dados, as árvores de decisão são subdivididas em duas principais abordagens: univariada e multivariada (SHRIVAS; DEWANGAN, 2014). Na abordagem univariada a divisão ocorre em um nó interno

usando apenas um atributo. A construção desse tipo de árvore de decisão pode ser feita por meio do algoritmo J48 (QUINLAN, 1992), implementado no aplicativo de mineração de dados WEKA, sendo uma extensão em código aberto (Java) do algoritmo C4.5.

A construção de árvores de decisão por meio do algoritmo J48 é feita a partir de um conjunto de dados de treinamento, utilizando-se o conceito de entropia (Equação 2.18). A divisão do conjunto de amostras em subconjuntos menores utiliza o critério de ganho de informação (Equação 2.19), por meio do qual é minimizado o total de entropia do subconjunto de dados (WU et al., 2008). O critério de parada da subdivisão do conjunto amostral inicia-se quando é identificado o maior ganho de informação para o atributo de determinada classe, resultando na decisão final do classificador (ONIK et al., 2015).

Para um conjunto de dados S, com c diferentes classificações tem-se:

$$Entropia(S) = \sum -p_i * \log_2 p_i, \text{ para } i = c$$
(2.18)

Em que  $p_i$  é a relação de instâncias de *S* pertencentes à classe *i*.

Para um atributo *A* a partir do conjunto *S* tem-se:

$$Ganho(S,A) = Entropia(S) - \sum (|S_v|/|S|) * Entropia(S_v)$$
(2.19)

Onde  $S_v$  é um subconjunto de *S* e o segundo termo da equação representa a entropia do conjunto após o uso do atributo *A* para classificá-lo.

A escolha do algoritmo J48 deve-se à sua popularidade ao ser considerado por Wu et al. (2008) como um dos melhores algoritmos de mineração de dados, além de outras características como, por exemplo, a capacidade de lidar com atributos discretos e contínuos. Para estes, o algoritmo J48 cria um valor limiar o qual é utilizado para particionar o conjunto de dados com valores de atributos maiores, menores ou iguais ao valor limite estabelecido (QUINLAN, 1996). O algoritmo J48 também se destaca pela capacidade de lidar com atributos que apresentem diferentes custos, além de permitir a poda de árvores após a criação. Nesse caso, o algoritmo retrocede pela árvore criada e tenta remover ramificações que não contribuem para o processo de decisão.

#### 2.4.4 Random Forest (RF)

*Random Forest* é definido por Breiman (2001) como um classificador formado por uma coleção de classificadores estruturados em árvores { $h(\mathbf{x}, \Theta_k), k = 1, ...$ }, as quais realizam um processo de votação da classe mais popular.  $\Theta_k$  são vetores aleatórios independentes e identicamente distribuídos; k é o número de árvores que crescem em função do conjunto de treinamento e de  $\Theta_k$ ; e  $\mathbf{x}$  é o vetor de entrada a partir do qual ocorre a votação de cada árvore para a classe mais popular. Após a geração de um grande número de árvores, o resultado alcançado pelo classificador é determinado pela maioria dos votos recebidos.

Breiman (2001) destacou que melhoras significativas na exatidão de classificação podem resultar de um crescente agrupamento de árvores de decisão aleatórias e do voto exercido por essas para a classe mais popular. Enquanto no algoritmo padrão de árvore de decisão todo o conjunto de dados é utilizado para formular a árvore, no algoritmo *Random Forest* o conjunto de dados é dividido aleatoriamente em diversos subconjuntos de tamanhos menores, criados por meio de amostragem com reposição, denominada *bootstrapping* (HAN; KAMBER, 2006).

Para cada subconjunto, uma árvore de decisão é criada formando um conjunto de classificadores (Figura 2.3). Esses deverão ser testados e avaliados quanto à contribuição para a classificação do objeto em estudo. A classificação é feita por meio de um sistema de votação, sobre qual classe determinado atributo deve pertencer. Para cada voto é estabelecido certo "peso", sendo este afetado por dois fatores: a correlação entre as árvores da floresta e a força individual (taxa de acerto) de cada árvore (BREIMAN, 2001; HAN; KAMBER, 2006).



Figura 2.3. Representação do processo de classificação Random Forest.

Fonte: Produção da autora.

O tempo computacional exigido pelo classificador *Random Forest* é definido por  $cT\sqrt{M}N \log(N)$ , em que *c* é uma constante, *T* é o número de árvores do conjunto, *M* é o número de variáveis e *N* é o número de amostras do conjunto de dados. Embora não seja tão exigente computacionalmente, o classificador requer certa quantidade de memória suficiente para armazenar o número de amostras do conjunto de dados em função do número de árvores totais (BREIMAN, 2001).

O mecanismo utilizado pelo classificador *Random Forest* para tratamento dos dados é conhecido como caixa preta (*black-box*). Gislason et al. (2006) sugeriram que, para estimativa da exatidão do conjunto teste, as amostras restantes do conjunto de treinamento de cada árvore, que não foram consideradas pelo processo *bootstrap*, poderiam ser avaliadas pelo método de validação-cruzada (*cross-validation*).

Pela capacidade de envolver diversas árvores de autoaprendizagem para parametrização e estimativa de variáveis categóricas ou contínuas, o classificador *Random Forest* lida de forma satisfatória com dados que apresentem alta dimensionalidade (GISLASON et al., 2006). É o caso dos dados hiperespectrais, que fornecem um grande número de variáveis de entrada (CLARK; ROBERTS, 2012).

# 2.5 Simulação estocástica

Os métodos de simulação estocástica são considerados importantes ferramentas para avaliar eventos próximos à realidade, como no caso da representação de uma área por meio de mapas de classificação. Pela simulação estocástica um modelo probabilístico é avaliado por meio da aleatorização das entradas no modelo. A partir de um grande número de repetições, portanto, garante-se que praticamente todas as combinações de entradas sejam avaliadas.

Os métodos de simulação fazem parte da ciência de processos estocásticos, os quais são definidos como uma família de variáveis aleatórias { $X(t), t \in T$ }, onde X(t) descreve a probabilidade no tempo t  $\in$  T (PRODAN; PRODAN, 2001). Os processos estocásticos originam-se de eventos aleatórios e apresentam alta capacidade de lidar com funções de densidade de probabilidade altamente estruturadas (DOYLE; RIEF, 1998).

Uma maneira de lidar com questões que envolvam a exploração de valores aleatórios, consiste na utilização do método de Monte Carlo. Esse método baseia-se em repetições aleatórias, ou cálculos iterativos, capazes de avaliar um modelo determinístico quando os dados de entrada do modelo dependem de parâmetros incertos (BLOCH; SØRENSEN, 2016).

Pelo método de Monte Carlo, uma sequência aleatória de números é utilizada para construir uma amostra da população, da qual estimativas estatísticas do parâmetro podem ser obtidas (HALTON, 1970). O método de Monte Carlo permite, portanto, a simulação de qualquer processo cujo desenvolvimento é influenciado por fatores aleatórios (DOYLE; RIEF, 1998).

Segundo Disney et al. (2000), o método de Monte Carlo tem sido amplamente utilizado em estudos que envolvam simulações em sensoriamento remoto. Doyle e Rief (1998) definiram a técnica de simulação estocástica de Monte Carlo como a abordagem mais eficiente em sensoriamento remoto para tratar a reflectância por meio de um modelo físico.

# 3 ÁREA DE ESTUDO

A área de estudo abrange parte do Parque Nacional de Brasília (PNB) - DF, situado entre os paralelos 15°35'S e 15°45'S e os meridianos 47°53'W e 48°05'W. O local de estudo consiste da área do PNB interceptada pela imagem Hyperion/EO-1, de órbita/ponto 223/70, e coordenadas centrais de 15°42' S e 48°0' W (Figura 3.1).



Figura 3.1. Mapa de localização do Parque Nacional de Brasília (PNB).

Fonte: Produção da autora.

O PNB insere-se na categoria de Unidades de Conservação de Proteção Integral, o qual foi criado pelo Decreto n° 241, de 29 de novembro de 1961. Inicialmente o Parque era constituído por uma área de 30.566,5940 hectares, sendo que, após a Lei n° 11.285, de 8 de março de 2006, a área do parque foi alterada para 42.355,54 hectares.

O PNB encontra-se praticamente dentro da bacia hidrográfica do Rio Paranoá e abriga as sub-bacias do Ribeirão do Bananal e do Ribeirão do Torto, o qual mantém o córrego Santa Maria como seu principal tributário. O Córrego dá origem à barragem de mesmo nome, inserida no PNB com uma área de contribuição de 101 Km<sup>2</sup>.

Os dados utilizados para a caracterização climatológica abrangem a região do Distrito Federal, uma vez que o PNB não dispõe de instrumentos para tal finalidade. As estações meteorológicas mais próximas estão situadas em Brasília, na sede do Instituto Nacional de Meteorologia (INMET), a 7 km ao sul do Parque, e nas proximidades da cidade-satélite de Planaltina, no Centro de Pesquisa Agropecuária dos Cerrados (CPAC) da Embrapa, aproximadamente a 28 km da sede do Parque.

Segundo a carta climática do Distrito Federal, a região do PNB está inserida em dois tipos de climas (classificação de Köppen), de acordo com a temperatura local: o Cwa, tropical de altitude com temperatura média variando entre 18°C e 22°C para cotas altimétricas de 1000 a 1200 m; e o Cwb, tropical de altitude com temperatura do mês mais frio inferior a 18°C, e média do mês mais quente inferior a 22°C (cotas altimétricas acima de 1200 metros) (FERREIRA, 2003a).

Além dos aspectos térmicos, a altitude também exerce influência sobre a pluviosidade, a qual é mais frequente em regiões de relevo acentuado. A pluviosidade ocorre devido à turbulência provocada sobre as correntes úmidas de orientação oeste-leste que atingem o Distrito Federal durante o verão. Por outro lado, a continentalidade e a ausência de ventos oceânicos acentuam a secura do ar, em razão da baixa umidade relativa, intensificando o período seco nos meses de agosto e setembro. Durante o inverno, quando coincide a estação seca, as chuvas são praticamente inexistentes, sendo que as poucas chuvas decorrentes da ação de frentes polares não são suficientes para modificar as condições de umidade do período seco.

A precipitação média anual na área do Distrito Federal é da ordem de 1.600 mm, sendo que as chuvas se concentram entre os meses de outubro a abril (SANO et al., 2001). Pode-se dizer que o ano de 2015 apresentou um total de precipitação inferior ao total dos últimos nove anos antecedentes (Figura 3.2). Enquanto que a média de precipitação total entre 2005 e 2014 foi de 1600,7 mm, a precipitação total para 2015 foi de apenas 1219,5 mm, sendo março o mês mais chuvoso (345,5 mm).



Figura 3.2 Precipitação total mensal (mm) entre os anos 2005 a 2014 (média) e do ano de 2015.

Fonte: INMET - Estação OMM: 83377-20/01/2016.

No contexto geomorfológico do Brasil Central, o PNB localiza-se no Domínio dos Planaltos em Estruturas Sedimentares Concordantes, Região do Planalto Goiás Minas e Região das Chapadas do Distrito Federal. Segundo o plano de manejo, três grandes unidades geomorfológicas são identificadas no PNB: a Chapada da Contagem, a Depressão do Paranoá e a Encosta da Chapada da Contagem.

Em linhas gerais, a geologia no PNB é caracterizada por duas grandes unidades litofaciológicas, pertencentes à sequência psamo-pelítica do Grupo Paranoá: uma litofácie basal (unidade das ardósias), constituída por sucessão composta predominantemente por ardósias, e uma litofácie de topo (unidade dos metarritmitos), caracterizada por metarritimitos com intercalações de quartzitos (FREITAS; CAMPOS, 1995).

A unidade das ardósias é pouco visível no PNB devido à sua baixa resistência aos processos de intemperismo na região. Fácies alteradas e parcialmente alteradas afloram, de forma descontínua, em voçorocas, e em algumas drenagens (localmente). Sobre esta unidade, desenvolvem-se espessos Latossolos. O contato com a unidade

dos metarritmitos ocorre próximo à Represa de Santa Maria, cuja fácies é recoberta na maior parte por Latossolos (FERREIRA, 2003a).

Segundo Ramos (1995), os principais grupos de solo encontrados no PNB são os Latossolos Vermelho-Escuro e Vermelho-Amarelo, os Cambissolos e os Solos Hidromórficos. O plano de manejo do Parque ainda ressalta a presença de Laterita Hidromórfica (Plintossolo) e de Areias Quartzosas.

Os Latossolos caracterizam-se por serem profundos, de textura argilosa ou média, porosos e bastante permeáveis. Esse solo favorece o estabelecimento de fitofisionomias como Cerrado *sensu stricto* e Campo Cerrado (PINHEIRO, 1999). Os Cambissolos, por sua vez, são pouco desenvolvidos, com baixa fertilidade e facilmente intemperizados. No PNB, as fitofisionomias favorecidas por esse tipo de solo são as do estrato herbáceo, tais como Campo Limpo e Campo Sujo. Já os solos Hidromórficos, observados em torno de drenagens ou pequenos córregos, apresentam um horizonte A bem desenvolvido. A vegetação nesse solo é marcada principalmente pela presença de murundus, que são pequenos morros secos distribuídos sobre uma superfície constantemente úmida ou intermitentemente alagada. O desenvolvimento de campos de murundus decorre da variação do nível freático, e as elevações de relevo são atribuídas à presença de elevado conteúdo de matéria orgânica nos solos e à atividade de argilominerais expansíveis.

A classe Laterita Hidromórfica caracteriza-se por apresentar solos com cores influenciadas pela redução e oxidação de ferro devido à oscilação do lençol freático. Situam-se em áreas menos alagadas e apresentam certa deficiência de nutrientes essenciais para o desenvolvimento da vegetação. As Areias Quartzosas, por sua vez, são solos pouco desenvolvidos constituídos por perfis profundos de sequência A e C, excessivamente drenados, porosos, de textura arenosa. Apresentam uma carência generalizada de nutrientes, elevada acidez e baixos teores de matéria orgânica.

A vegetação dominante no PNB é o Cerrado definido por Coutinho (1978) como um complexo de formações oreádicas, que vão desde o Campo Limpo até o Cerradão. As formas savânicas (Campo Sujo, Campo Cerrado e Cerrado *sensu stricto*) são

verdadeiros ecótonos de vegetação entre aquelas duas formas extremas: a florestal, representada basicamente pelo Cerradão, e a campestre constituída pelo Campo Limpo.

De acordo com a classificação de Ribeiro e Walter (1998), as fitofisionomias presentes no PNB estão divididas em três estratos de vegetação: estrato herbáceo arbustivo (Campo Limpo - CL e Campo Sujo - CS); estrato arborescente (Campo Cerrado - CC e Cerrado *sensu stricto* - CSS); e estrato arbóreo (Mata de Galeria – MG). A Tabela 3.1 traz algumas informações sobre a ocorrência dessas classes no PNB, conforme proposto por Ribeiro e Walter (1998).

Tabela 3.1 Características das fitofisionomias encontradas no Parque Nacional de Brasília (PNB).

Formação Cerrado	Características da Paisagem	Cobertura arbórea (%)	Altura média das árvores(m)
Campo Limpo	Campo aberto	< 1	-
Campo Sujo	Campo aberto com arbustos espaçados	< 5	2
Campo Cerrado	Arbustos com árvores espaçadas	5-20	2-3
Cerrado sensu stricto	Mistura de campo, arbustos e árvores com mais de sete metros	2 -50	3-6
Mata de Galeria	Vegetação densa, sempre verde, principalmente ao longo de cursos d'água	40-70 na estação seca; 50-90 na estação chuvosa	20-30

Fonte: Ferreira (2003a).

O mapa atualizado de vegetação do PNB, proposto por Ferreira (2003a) traz, dentre outras correções, a atualização da nomenclatura de algumas fitofisionomias de acordo com o estudo de Eiten (2001). As classes antes identificadas por "Invasoras/Pioneiras" e "Campo Rupestre", por exemplo, foram renomeadas para "Campo Cerrado com

Trembleias" e "Campo Sujo com presença de Arnica (*lycnophora ericoides*) e Canela de Ema", respectivamente. Em outro exemplo, áreas definidas por "Parque de Cerrado" passaram a ser identificadas como "Campo Limpo com Murundus". Tais mudanças foram baseadas na constatação da presença dessas espécies em determinados pontos do parque, considerando-se também a caracterização estrutural das mesmas (FERREIRA, 2003a).

Uma característica básica da formação Campo Limpo consiste na dominância absoluta de plantas herbáceas. A vegetação alcança entre 20-120 cm de altura e praticamente não existe serrapilheira, pois a frequência de ocorrência de fogo é alta. As plantas crescem muito próximas entre si e a forma de vida dominante é do tipo perene recorrente, isto é, aquela em que a parte aérea seca e se renova a cada ano. Dominam entre os arbustos *Byrsonima basiloba, Sabicea brasiliense, Davilla elliptica, Spiranthera odoratissima, Diplusodon oblongus e Palicourea rigida.* Entre as herbáceas merecem menção: *Palicourea coriacea, Borreria* spp., *Lupinus velutinus, Angelonia crassifolia, Amasonia hirta, Hyptis* spp. e Calea spp.. Entre as inúmeras gramíneas cabe destacar as grandes populações de *Trystachy leiostachy*, além de *Echinolaena inflexa, Axonopus aureus, A. chrysoblepharis, A. barbigerus, Panicum cervicatum, P. olyroides, Paspalum erianthum, P. stellatum e P. gardnerianum.* 

O plano de manejo do PNB descreve a formação Campo Limpo com murundus como uma vegetação especial que ocorre em pequenas manchas dentro do parque. Caracteriza-se pela presença de montículos geralmente arredondados de 80-180 cm de altura em meio a uma vegetação rasteira. Duas formas de campo de murundus estão presentes no PNB: uma brejosa e outra seca. A forma brejosa, mais frequente, caracteriza-se por apresentar sobre os murundus uma flora típica de cerrado entremeada com elementos de brejo e outra típica de brejo nos espaços entre os montículos. Sobre os murundus são frequentes: *Protium ovantum, Symplocos nitens, Microlicia hirsutissima, Miconia albicans, Maprounea brasiliensis, Estehrazia splendida*, etc. Entre os murundus são encontradas as espécies *Paspalum hyalinum, Axonopus comans, Agenium goyazense*, além de *Trembleya parviflora, Lycopodiella cernua e Rhynchospora* spp.. Na forma seca, os murundus são colonizados

principalmente por espécies de cerrado tais como: *Trachypogon montufari*, *Schizaachyrium tenerum*, *Styrax ferrugineum*, *Didymopanax macrocarpum*, *Sabicea brasiliensis*, enquanto nos espaços entre eles ocorrem plantas de campo úmido e brejo: *Axonopus comans*, *Hypogynium virgatum*, *Paepalanthus* spp., *Xyris spp. e Arthropogon villosus*.

Segundo Ribeiro e Walter (2008), a formação Campo Cerrado é a formação campestre com predomínio de espécies herbáceas e algumas arbustivas, com ausência de árvores na paisagem. Quando naturais, são delimitadas pelas áreas encharcadas das depressões. Pode também ocorrer em solos rasos, com presença de afloramentos rochosos, possuindo uma composição diferenciada de espécies, com plantas adaptadas a esse ambiente.

O Campo Sujo caracteriza-se pela presença de árvores esparsas em meio à camada rasteira, que é dominante. A espécie arbórea dominante é *Vochysia thyroidea* (gomeira), mas ocorrem também *Qualea* spp., *Vochysia rufa*, *Byrsonima verbascifolia* e *Piptocarpha rotundifolia*. As espécies da camada rasteira são as mesmas do Cerrado sensu stricto, mas há dominância dos graminóides e aparecem também *Paepalanthus* spp. e muitas Compostas (*Calea, Vernonia, Aspilia* e *Eremnthus*).

Na formação Cerrado *sensu stricto* é enorme a diversidade florística tanto no estrato arbóreo quanto no rasteiro. Destacam-se, no estrato arbóreo: *Kielmeyera coriacea*, *Ouratea hexasperma*, *Dalbergia miscolobium*, *Tryphnodendron adstringens*, *Caryocar brasiliense*, *Pterodon pubescens*, *Chamaecrista claussenii* e *Chamaecrista orbiculata*. As espécies mais frequentes da camada rasteira são Echinolaena inflexa, *Axonopus marginatus*, *Myrcia lineacarifolia*, *Myrcia dyctiophylla*, *Trachypogon montufari* e *Calliandra dyantha*.

Como espécies da formação Mata de Galeria, citadas pelo plano de manejo, destacamse: *Calophyllum brasiliense*, *Tapirira guianensis*, *Ixora warmingii*, *Vochysia pyramidalis*, *Virola sebifera*, etc. Na camada rasteira destacam-se *Panicum sellowii*, *Olyra latifolia*, *Psycothria hoffmanseggiana* e *Serjania lethalis*. No Parque há ainda uma composição florística bastante diferenciada, com presença de *Anadenanthera*  colubrina, Maytenus cf. Floribunda, Eriotheca gracilipes, Zanthoxylum rhoifolium, além de Dalbergia frutesceus, Schinus sp., Pouteria sp. e Micropholis rigida.

#### 4 METODOLOGIA

As etapas metodológicas a serem seguidas neste estudo estão sintetizadas no fluxograma da Figura 4.1 e serão detalhadas nas subseções a seguir.





Fonte: Produção da autora.

### 4.1 Seleção da área de estudo e das imagens Hyperion/EO-1

O PNB foi escolhido por apresentar área relativamente extensa e preservada, com algumas fitofisionomias representativas do ecossistema Cerrado. Além disso, dispõe de imagens orbitais do período chuvoso e seco, e de um mapa de vegetação elaborado por Ferreira (2003a), utilizando dados de campo.

Nesse estudo, foram escolhidas quatro imagens Hyperion/EO-1 para a investigação da influência espectral da sazonalidade no Cerrado. Dentre essas imagens, apenas dados de duas datas (13/01/2015 e 24/06/2015), representativas dos períodos chuvoso e seco, respectivamente, foram selecionados para aplicar os algoritmos de classificação. Apesar de não haver as mesmas condições de iluminação nas cenas, a escolha das duas imagens decorreu da semelhança dos ângulos de visada do sensor, sendo esses -28,80° (janeiro) e -29,45° (junho), minimizando ao máximo a influência dos fatores externos sobre a análise sazonal da vegetação. A Tabela 4.1 apresenta as características geométricas da coleta de dados nas cenas selecionadas para este estudo.

Data	Ângulo azimutal solar	Ângulo zenital solar	Ângulo de visada do sensor
13/01/2015	104,8°	49,7°	-28,80°
31/05/2015	53,4°	61,4°	-3,96°
24/06/2015	54,7°	66,2°	-29,45°
07/08/2015	59,2°	59,4°	18,51°

Tabela 4.1 Características geométricas da coleta de dados nas cenas selecionadas para estudo.

Fonte: Earth Explorer/USGS.

Devido à área de abrangência das imagens Hyperion/EO-1, as classes de vegetação consideradas neste estudo foram: Campo Cerrado (CC); Campo Cerrado com Trembleias (CCT); Campo Limpo (CL); Campo Limpo com Murundus (CLM); Campo Sujo (CS); Campo Sujo com presença de *Lychnophora ericoides* (Arnica) e *Vellozia squamata* (Canela de Ema) (CS/A/CE); Cerrado *Sensu Stricto* (CSS); e Mata de Galeria (MG), totalizando oito classes fitofisionômicas (Figura 4.2). Além das classes citadas, a imagem Hyperion/EO-1 abrangeu classes de brejo (B), matas de interflúvio (MI), solo exposto e corpo d'água, que neste estudo foram desconsideradas.

Figura 4.2 Representação de algumas fitofisionomias na área de estudo: Campo Limpo (CL), Campo Sujo (CS), Campo Cerrado (CC), Cerrado *sensu stricto* (CSS) e mata de galeria (MG).



Fonte: Adaptado de Ferreira (2003a).

### 4.2 Pré-processamento das imagens Hyperion/EO-1

Os dados das imagens Hyperion/EO-1 foram processados com o objetivo de corrigir os artefatos das imagens e os efeitos atmosféricos. Neste trabalho foi utilizado um algoritmo para redução do efeito *striping*, o qual consiste em informações perdidas durante a aquisição dos dados, sendo representado em forma de "faixas escuras", perpendiculares à linha de varredura. O algoritmo foi aplicado sobre a imagem Hyperion/EO-1 de forma a substituir a linha vertical anormal pela resposta média das colunas adjacentes (Galvão et al., 2009a).

Os dados de radiância foram convertidos para dados de reflectância de superfície utilizando o *Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes* (FLAASH) do aplicativo ENVI, o qual é baseado no modelo de transferência radiativa MODTRAN-4 (*Moderate Resolution Transmittance Code*) (FELDE et al., 2003). O principal objetivo da aplicação da função FLAASH é a remoção dos efeitos de espalhamento e de absorção da radiação solar, devido à influência de constituintes atmosféricos. O programa requer parâmetros de entrada como data e horário da aquisição das imagens, latitude e longitude do centro da cena, elevação média e visibilidade a ser utilizada para estimar, *pixel* a *pixel*, a quantidade de vapor de água presente na atmosfera. O modelo atmosférico e o modelo de aerossol utilizados foram o tropical e o rural, respectivamente, utilizando a banda de absorção posicionada em 1135 nm para o cálculo do vapor d'água *pixel* a *pixel*.

Ainda na etapa de pré-processamento das imagens foi feito o registro das cenas, fixando pontos de controle para tal finalidade. O registro objetivou alocar os respectivos *pixels* de cada cena sobre mesmas coordenadas geográficas para que as análises espectrais fossem realizadas de forma coerente.

### 4.3 Extração dos atributos hiperespectrais

Para extração dos atributos hiperespectrais, considerou-se 146 bandas estreitas, estando posicionadas entre 436 e 701 nm na região do visível (VIS); entre 711 e 905 nm e 972 e 1336 nm na região do infravermelho próximo (NIR); entre 1487 e 1769 nm

na região do infravermelho de ondas curtas 1 (SWIR 1); e entre 2032 e 2355 nm na região do infravermelho de ondas curtas 2 (SWIR 2).

Os atributos abordados neste estudo foram: 1) reflectância das 146 bandas do Hyperion; 2) derivada de primeira ordem da reflectância das 146 bandas; 3) 22 índices de vegetação (IVs) de bandas estreitas; 4) 24 parâmetros descritores de feições de absorção calculados com o método de remoção do contínuo espectral; e 5) todos os atributos em conjunto.

Os dados de radiância corrigidos atmosfericamente permitiram a extração dos valores de reflectância para cada *pixel* das cenas. Nessa etapa foram consideradas as diferentes intensidades de brilho para cada imagem dos períodos chuvoso e seco. Os parâmetros de bandas de absorção e a derivada de 1ª ordem dos espectros foram avaliados por meio do aplicativo *Processing Routines in IDL for Spectroscopic Measurements* – PRISM (KOKALY, 2011). Ele é composto por programas escritos em linguagem IDL, sendo executáveis no aplicativo de processamento de imagens ENVI.

O atributo derivada de 1<sup>a</sup> ordem também foi útil na análise sazonal no que diz respeito à borda vermelha (*red edge*) que ocorre no intervalo espectral de 690-750 nm, já que o *Red Edge Position* (REP) é definido como o valor máximo da 1<sup>a</sup> derivada em um determinado comprimento de onda no referido intervalo.

Neste estudo, também foram considerados os principais índices de vegetação de bandas estreitas (Tabela 4.2) sugeridos por Roberts et al. (2011). São eles: *Normalized Difference Vegetation Index* (NDVI); *Enhanced Vegetation Index* (EVI); *Visible Index Green* (VIg); e *Visible Atmospherically Resistant Index* (VARI), sendo esses associados à estrutura da vegetação. Os IVs relacionados aos elementos bioquímicos foram: *Moisture Stress Index* (MSI); *Normalized Difference Infrared Index* (NDII); *Structure Insensitive Pigment Index* (SIPI); *Normalized Difference Water Index* (NDWI); *Water Band Index* (WBI); *Pigment Specific Simple Ratio* (PSSR); *Plant Senescence Reflectance Index* (PSRI); *Modified Chlorophyll Absorption Ratio Index* (MCARI); *Anthocyanin Reflectance Index* (ARI); *Cellulose Absorption Index* (CAI); *Normalized Difference Lignin Index* (NDLI); *Carotenoid Reflectance Index 1* (CRI1); e *Leaf Water Vegetation Index 2* (LWVI2). Finalmente, para a obtenção de métricas hiperespectrais nas faixas do VIS e NIR, associadas aos aspectos fisiológicos da vegetação, foram utilizados os índices de vegetação *Red Edge Position Index* (REPI); *Vogelmann Red Edge Index* (VOG); *Red Edge Normalized Difference Vegetation Index* (RENDVI); *Photochemical Reflectance Index* (PRI); *Red-Edge Vegetation Stress Index* (RVSI).

Índice de Vegetação	Equação	Referência				
	Estrutura					
NDVI	$(\rho 864 - \rho 660) / (\rho 864 + \rho 660)$	Rouse et al. (1974)				
EVI	$2.5 \times ((\rho 864 - \rho 660)  /  (\rho 864 + 6 \times \rho 660 - 7.5 \times \rho 487 + 1))$	Huete et al. (2002)				
VIg	$(\rho 559 - \rho 660) / (\rho 559 + \rho 660)$	Gitelson et al. (2002a)				
VARI	(p559 – p660) / (p559 + p660 - p487)	Gitelson et al. (2002a)				
	Bioquímica					
MSI	(ρ1598) / (ρ823)	Hunt; Rock (1989)				
NDII	$(\rho 823 - \rho 1649) / (\rho 823 + \rho 1649)$	Hunt; Rock (1989)				
SIPI	$(\rho 803 - \rho 467) / (\rho 803 + \rho 681)$	Peñuelas et al. (1995)				
NDWI	$(\rho 854 - \rho 1245) / (\rho 854 + \rho 1245)$	Gao (1996)				
WBI	ρ905 / ρ972	Peñuelas et al. (1997)				
PSSR	ρ803 / ρ671	Blackburn (1998a)				
PSRI	(p681 - p498) / p752	Merzlyak et al. (1999)				
MCARI	[(ρ701 - ρ671) - 0.2× (ρ701 - ρ549)] × (ρ701/ρ671)	Daughtry (2000)				
ARI	$(1/\rho 559) - (1/\rho 721)$	Gitelson et al. (2001)				
CAI	$100 \times [0.5 \times (\rho 2032 + \rho 2213) - \rho 2102]$	Daughtry (2001)				
NDLI	$[\log(1/\rho 1754) - \log(1/\rho 1680)] / [\log(1/\rho 1754) + \log(1/\rho 1680)]$	Serrano et al. (2002)				
CRI1	$(1/\rho 510) - (1/\rho 550)$	Gitelson et al. (2002b)				
LWVI2	$(\rho 1094 - \rho 1205) / (\rho 1094 + \rho 1205)$	Galvão et al. (2005)				
Fisiologia						
REPI	(máxima primeira derivada no intervalo 690-740 nm)	Horler et al. (1983)				
VOG	ρ742 / ρ722	Vogelmann et al. (1993)				
RENDVI	$(\rho 752 - \rho 701) / (\rho 752 + \rho 701)$	Gitelson et al. (1996)				
PRI	$(\rho 529 - \rho 569) / (\rho 529 + \rho 569)$	Gamon et al. (1997)				
RVSI	$[(\rho 712 + \rho 752)/2] - \rho 732$	Merton; Huntington (1999)				

Tabela 4.2 Índices de vegetação (IVs) de bandas estreitas usados para geração de métricas hiperespectrais.

ρ representa a reflectância da banda mais próxima do sensor Hyperion ao comprimento de onda original das formulações.

Fonte: Adaptado de Roberts et al. (2011).

Finalmente, utilizando o método de remoção do contínuo (CLARK; ROUSH, 1984; SANCHES et al., 2015), descrito na Fundamentação Teórica, foram calculadas a profundidade, largura, área e assimetria das seguintes bandas de absorção: clorofila (centro em 680 nm), água foliar (feições em 980 e 1200 nm); e lignina-celulose (absorções em 1700, 2100 e 2300 nm).

#### 4.4 Caracterização espectro-temporal

A análise espectro-temporal das fitofisionomias inseridas no PNB foi realizada por meio dos atributos reflectância, derivada de 1<sup>a</sup> ordem, índices de vegetação e parâmetros de bandas de absorção. Devido à limitação para aquisição de imagens sem nuvens no período chuvoso, considerou-se apenas a cena de janeiro para a representação desse período, enquanto que para o período seco foram consideradas as cenas de maio, junho e agosto.

Para a análise do comportamento espectro-temporal dos atributos, considerou-se um conjunto de 640 *pixels*, subdivididos em 80 *pixels* para cada uma das oito fitofisionomias. Foram gerados perfis espectro-temporais por fisionomia e data de aquisição da imagem e foram obtidos gráficos de espalhamento para pares de atributos. Na análise dos resultados, nem todas as fitofisionomias puderam ser analisadas temporalmente, data-a-data. Isso ocorreu porque houve pequenas diferenças na largura das faixas de imageamento do Hyperion, causando a exclusão da análise das classes CS/A/CE que não foi imageada em todas as cenas.

### 4.5 Seleção de atributos

A seleção de atributos foi realizada no aplicativo WEKA (3.8), utilizando o método de avaliação de atributos CFS, conforme recomendado por Hall (1999). Segundo o autor, o método CFS pode ser comparado, em termos de desempenho, ao algoritmo *wrapper*, o qual tem sido implementado em novos aplicativos de processamento de imagens hiperespectrais, tais como o *EnMAP-Box* (LINDEN, VAN DER et al., 2015). A utilização do CFS baseia-se também em resultados que mostram que este método seleciona subconjuntos de atributos de tamanho semelhante àqueles selecionados pelo

método *wrapper*. O método *wrapper* avalia os atributos de um conjunto de dados utilizando um algoritmo de aprendizagem. Hall (1999) destacou ainda que ambos os métodos de avaliação reduzem, de maneira similar, a árvore de decisão C4.5, utilizada como base para a árvore de decisão J48 abordada neste estudo.

Para diferentes avaliações de atributos estão associados diferentes métodos de busca, os quais permitem a identificação da maioria dos atributos irrelevantes, contribuindo para a otimização no tempo de processamento. Dentre esses, destacam-se os métodos *Best First* e *Greedy stepwise*, recomendados por Onik et al. (2015), os quais obtiveram acurácia de 99,25% no estudo desses autores, considerando o avaliador de atributos CFS, numa classificação feita por árvore de decisão J48.

O método de busca considerado neste estudo foi o *Best First* que procura o subconjunto do espaço de atributos pela técnica denominada *greedy hill climbing*. Essa técnica determina o número de nós consecutivos que não podem ser melhorados, permitindo o controle do nível de rastreamento realizado na busca do espaço de atributos. O método *Best First* pode iniciar-se com um conjunto vazio de atributos e realizar a busca progressivamente, ou iniciar-se com um conjunto completo de atributos e realizar a busca retroativamente, ou ainda iniciar-se em qualquer ponto e realizar a busca em ambas as direções.

Na etapa de seleção de atributos, foram considerados os atributos reflectância, a derivada de 1ª ordem dos espectros, os parâmetros de bandas de absorção, os índices de vegetação e todos os atributos em conjunto. A seleção foi feita para ambos os períodos, chuvoso e seco, sendo que os atributos selecionados foram utilizados como dados de entrada para os algoritmos de classificação.

#### 4.6 Classificação das fitofisionomias do PNB

Para a etapa de classificação foram consideradas as imagens de janeiro (período chuvoso) e de junho (período seco), com ângulos de apontamento do sensor similares. As classificações foram realizadas pelos algoritmos *Spectral Angle Mapper* (SAM), *Support Vector Machine* (SVM), Árvore de Decisão J48 e *Random Forest* (RF), tendo

como dados de entrada os conjuntos de atributos selecionados pelo algoritmo CFS. Os cinco conjuntos de atributos considerados nessa etapa referem-se à reflectância, derivada de 1ª ordem dos espectros, índices de vegetação, parâmetros de bandas de absorção e todos os atributos juntos. Considerando, portanto, os quatro algoritmos de classificação e os cinco conjuntos de atributos, foram gerados no total vinte mapas temáticos para cada um dos períodos em questão.

A classificação pelo algoritmo SAM foi efetivada no aplicativo ENVI 4.8, em que foram gerados oito espectros de referência para cada atributo e cada fitofisionomia, a partir da média espectral dos atributos selecionados (1077 *pixels*). Já as classificações SVM, J48 e RF foram feitas usando o aplicativo WEKA. Para a classificação SVM foi utilizado o algoritmo *Optimization Minimal Sequential* (SMO) implementado por Platt (1999), bem como definida a função kernel *Pearson VII function-based universal kernel* (PUK) (ÜSTÜN et al., 2006). Para a árvore de decisão J48 foi definido como 10 o número mínimo de *pixels* a ser considerado por folha.

Para a geração dos mapas classificados, considerou-se um grupo de 1077 *pixels* para calibração e 1068 *pixels* para validação. Esses *pixels* foram extraídos de diferentes polígonos na imagem representando as fitofisionomias para evitar efeitos de autocorrelação. Selecionou-se preferencialmente os polígonos visitados na atividade de campo executada em julho de 2016. A calibração do modelo foi feita pelo método *10-fold cross-validation* inserido no aplicativo WEKA. As amostras foram selecionadas com base nas fitofisionomias do mapa de vegetação do PNB, elaborado por FERREIRA (2003a), e com base nas observações de campo.

O mapa de vegetação (Figura 4.3), que serviu como referência, foi elaborado por Ferreira (2003a) por meio da análise de duas cenas do sensor orbital IKONOS, com resolução espacial variando entre 1 e 4 metros, e por uma imagem ETM+/Landsat-7 para fins de complementação da cobertura do parque. O autor utilizou um Modelo Linear de Mistura Espectral (MLME), usando *endmembers* coletados das próprias cenas, bem como *endmembers* gerados por meio de espectroscopia aérea sobre o PNB. A elaboração do mapa foi suportada por atividades de campo.

Apesar do mapa de vegetação do PNB (FERREIRA, 2003a) ter sido atualizado em 2007 por Ferreira et al. (2007), este não trouxe a localização das fitofisionomias com presença de espécie invasora (trembleia) e da vegetação com arnica e canela de ema. Dessa forma, optou-se por utilizar o mapa mais antigo de 2003, visto que era de interesse deste estudo avaliar o comportamento espectral dessas fitofisionomias e a influência exercida por essas espécies diante dos algoritmos de classificação.





Fonte: Ferreira (2003a).

# 4.6.1 Análise de incerteza das classificações

A análise de incerteza dos mapas classificados baseou-se nos parâmetros estatísticos obtidos por meio de matrizes de confusão e índice Kappa, além do cálculo da entropia de Shannon, possibilitando abordagem mais completa a respeito do desempenho dos algoritmos de classificação.

As matrizes de confusão seguem metodologia padrão e ainda hoje são amplamente aceitas para avaliar o desempenho de um algoritmo de classificação (CONGALTON, 1991). Pela matriz, pode-se determinar a exatidão total, a qual é computada pela divisão da soma dos *pixels* classificados corretamente (expressos pela diagonal principal) pelo número total de *pixels*. Para determinada classe, a divisão do número de *pixels* classificados corretamente pelo número total de *pixels* dessa classe indicados como referência proporciona a chamada exatidão do produtor. Já a exatidão do usuário para determinada classe é obtida pela divisão do número de *pixels* corretamente classificados pelo total de *pixels* classificados nessa categoria (CONGALTON, 1991).

Outra métrica estatística utilizada neste trabalho consiste no índice Kappa (COHEN, 1960). A estatística Kappa é uma medida de concordância que nos fornece uma ideia do quanto as observações se afastam daquelas esperadas, em decorrência do acaso. Os valores de Kappa variam entre 0 e 1, sendo que "0" significa não haver concordância além do puro acaso, e "1" representa a concordância perfeita. Em situações raras, o Kappa pode assumir valores negativos, o que implica no fato de as duas observações concordarem menos do que o esperado apenas pelo acaso. Na Equação 4.20, Congalton (1991) define a fórmula para o cálculo da estatística Kappa, dada pela razão da diferença entre a concordância observada e a concordância esperada pelo acaso.

$$Kappa = \frac{N\sum_{i=1}^{r} x_{ii} - \sum_{i=1}^{r} (x_{i+} \cdot x_{+i})}{N^2 - \sum_{i=1}^{r} (x_{i+} \cdot x_{+i})}$$
(4.20)

Onde *r* é o número de linhas da matriz de confusão,  $x_{ii}$  é o número de observações na linha *i* e coluna *i*,  $x_{i+}$  e  $x_{+i}$  são os totais de linhas *i* e colunas *i*, respectivamente, e *N* é o número total de observações.

Adicionalmente às matrizes de confusão e estatística Kappa, optou-se ainda por quantificar a incerteza das classificações por meio da entropia de Shannon (H) (Equação 4.21), considerada uma medida do grau de desordem de um sistema (SHANNON, 1948). Para este estudo, o cálculo da entropia de Shannon objetivou avaliar a consistência metodológica em relação às regras de decisão utilizadas pelos algoritmos de classificação para cada um dos atributos testados.

$$H = -\sum_{i} p_i^2 \log(p_i^2)$$
(4.21)

Em que  $p_i$  é o número de ocorrência de um valor em relação a todas as ocorrências possíveis de serem obtidas.

### 4.7 Avaliação das classificações por meio de simulação estocástica

A avaliação estatística das classificações foi feita por meio da técnica de simulação estocástica sobre o índice Kappa, realizada pelo aplicativo MATLAB R2013a. Por essa técnica foram geradas 10.000 matrizes de confusão, mediante a seleção aleatória de 250 *pixels* dentre os 1068 *pixels* referentes ao conjunto de validação. Dentre esses 250 *pixels*, foi considerado um percentual para cada fitofisionomia avaliada neste estudo por meio da proporção de *pixels* de cada fitofisionomia em relação aos 1068 *pixels*. Após a geração das 10.000 matrizes de confusão, foi possível obter as funções de distribuição de probabilidade (FDP) dos índices Kappa para os períodos chuvoso e seco.

Após a geração das FDPs, foram calculadas as diferenças de Kappa entre os valores dos períodos seco e chuvoso, obtendo-se a FDP da diferença para cada uma das classificações. A partir das FDPs das diferenças de Kappa, estabeleceu-se um intervalo de credibilidade de 99% para avaliar se as classificações dos períodos chuvoso e seco diferiam estatisticamente entre si. Se a amplitude do intervalo de credibilidade não englobasse o valor zero, então, assume-se que há evidências para rejeitar a hipótese nula ( $H_0$ ) de não haver diferença entre os períodos. A igualdade entre os períodos chuvoso e seco foi representada pelo valor de Kappa igual a zero. Um gráfico *boxplot* foi gerado para representar as FDPs de diferença de Kappa para todas as classificações.

Ainda por meio da simulação estocástica, para cada uma das fitofisionomias, foram ordenados os percentuais de acerto em relação às cinco melhores classificações. De um total de *pixels* associados a cada fitofisionomia de referência, foram selecionados 250 *pixels* aleatórios e calculado o percentual de acerto para essas. O cálculo foi feito dividindo-se o total de *pixels* classificados como a fitofisionomia de referência, pelos 250 *pixels* selecionados. O processo de seleção dos *pixels* foi iterado 10.000 vezes originando, assim, a FDP de acerto das fitofisionomias para cada classificação, sendo essas representadas num gráfico *boxplot*.
### **5 RESULTADOS E DISCUSSÃO**

#### 5.1 Caracterização sazonal da resposta espectral das fitofisionomias do PNB

### 5.1.1 Influência da geometria de aquisição de dados

A geometria de aquisição dos dados exerceu influência sobre os valores de radiância das cenas nos períodos chuvoso e seco. Em decorrência da gradual deriva do satélite EO-1, a partir do ano de 2011, e do decaimento do horário local médio de passagem, as imagens adquiridas no ano de 2015 foram caracterizadas por um decréscimo na magnitude dos valores de reflectância em função do aumento do ângulo zenital solar (AZS), quando comparado ao horário original de passagem do satélite no Equador (10:00 h da manhã). Para os meses de janeiro a agosto do ano de 2015, o horário de passagem do satélite ocorreu entre 8:45 e 9:00 h da manhã, portanto, diferente das 10:00 h da concepção original do satélite (LANDIS et al., 2016). Portanto, quando comparado às imagens adquiridas antes de 2011, o sensor registrou maiores quantidades de sombreamento na vegetação.

Landis et al. (2016) mostraram que a densidade de energia incidente foi mais alta em observações no solstício de verão para latitudes mais elevadas. Sob o horário local médio de 8:00 h da manhã, essas latitudes receberam cerca de 80% da radiância incidente quando comparado a 100% às 10:00 h da manhã. No entanto, a redução no horário local médio de passagem proporcionou degradação mínima para determinados locais, não impedindo a capacidade de coleta de dados (LANDIS et al., 2016). Os espectros de reflectância das fitofisionomias campestres (Figura 5.1) e arbóreas (Figura 5.2) mostraram comportamento distinto nos períodos chuvoso e seco.

Figura 5.1 Resposta espectral sazonal das fitofisionomias campestres Campo Limpo (CL), Campo Limpo com Murundus (CLM), Campo Sujo (CS) e Campo Sujo com presença de Arnica e Canela de Ema (CS/A/CE).



Fonte: Produção da autora.

As diferenças sazonais entre as curvas espectrais das fitofisionomias são resultantes não apenas do aumento na quantidade de massa seca e da maior exposição do substrato com a diminuição do índice de área foliar (IAF) no período seco. Essas diferenças também são decorrentes dos maiores valores de AZS e da diminuição do ângulo azimutal solar (AAS) de janeiro para junho, em combinação com o ângulo de apontamento elevado do sensor (Tabela 4.1). Considerando a mudança no horário de passagem do satélite em 2015, enquanto que para o período chuvoso o AZS foi de 49,7°, para o período seco esse ângulo foi de 66,2°. Fitofisionomias como Mata de Galeria (MG) não deveriam apresentar diferenças espectrais significativas em ambos os períodos de aquisição das imagens, como observado por Jacon et al. (2017).

Figura 5.2 Resposta espectral sazonal das fitofisionomias arbóreas Campo Cerrado (CC), Campo Cerrado com Trembleias (CCT), Cerrado sensu stricto (CSS) e Mata de Galeria (MG).



Fonte: Produção da autora.

Assumindo-se que as imagens de janeiro e junho apresentam condições de geometria de visada semelhantes (-28.80° e -29,45°, respectivamente), foi possível mensurar a influência da mudança do AZS na variação de intensidade de brilho das cenas. A mensuração foi feita dividindo-se o cosseno do AZS de janeiro pelo de junho, e dividindo-se a radiância média de janeiro pela de junho, obtendo-se as razões R1 e R2, respectivamente. A razão entre R1 e R2 gerou a proporção de brilho explicada pela variação do cosseno dos ângulos zenitais (Tabela 5.1).

Tabela 5.1. Proporção de brilho explicada pela variação do cosseno dos ângulos zenitais.

Região espectral	Média Cos ( $\theta$ ) (%)
Vis	90,6
NIR	75,0
SWIR 1	75,8
SWIR 2	63,7

Fonte: Produção da autora.

Pela Tabela 5.1 temos que, no PNB, para a região do visível, 90,6% da variação da radiância média da cena menos brilhante (junho) para a cena mais brilhante (janeiro) é explicada pela variação do cosseno do ângulo zenital solar entre as cenas. Para a região do NIR, a variação do ângulo zenital solar entre as cenas explica 75,0% da variação de brilho. As regiões do SWIR 1 e SWIR 2 apresentaram, respectivamente, 75,8% e 63,7% da variação de brilho explicada pela variação do cosseno dos ângulos zenitals.

O decréscimo do percentual de variação de brilho explicado pela variação do cosseno dos ângulos zenitais, ao longo do espectro, ocorreu devido à redução da quantidade de energia nos maiores comprimentos de onda. A baixa quantidade de energia permite que outras variáveis externas também exerçam influência sobre a variação de brilho, como pôde-se observar na região do SWIR 2 em relação à região do visível.

### 5.1.2 Variação sazonal dos atributos hiperespectrais

# 5.1.2.1 Reflectância

Os espectros de reflectância das fitofisionomias Campo Limpo (CL) e Cerrado *sensu stricto* (CSS) apresentaram diferenças espectrais marcantes associadas à sazonalidade dos períodos chuvoso e seco (Figura 5.3).





Fonte: Produção da autora.

Na região espectral do visível, onde ocorre absorção da radiação devido à atuação de pigmentos fotossintetizantes, nota-se do período chuvoso para o seco, a redução do pico de reflectância no verde em ambas as fitofisionomias.

Ainda na região do visível, comparando-se as duas fitofisionomias no período seco, observa-se menor profundidade na banda de absorção de clorofila (680 nm) para a fitofisionomia CL. Esse fato decorre provavelmente de sua maior sensibilidade ao déficit hídrico, o que torna a perda de pigmentos fotossintetizantes mais acentuada em relação às fitofisionomias mais densas (CARVALHO et al., 2007).

A perda de pigmentos resulta no processo de senescência das gramíneas, contribuindo para consequente aumento da reflectância na região do visível. Para ambos os períodos, as feições de absorção de clorofila em 450 nm e 680 nm foram mais notórias para a fitofisionomia CSS, permitindo a manutenção da atividade fotossintética, já que essa é menos sensível ao déficit hídrico no período seco.

Os valores mais altos de reflectância na região espectral do NIR são resultantes do espalhamento de fótons nos espaços intracelulares das células do mesófilo esponjoso (WOOLLEY, 1971). Já as feições de absorção nos comprimentos de onda de 1000 e 1200 nm resultam da presença de água no interior das folhas, ocorrendo de forma mais acentuada para a fitofisionomia CSS (ASNER, 1998).

As regiões espectrais do SWIR 1 e do SWIR 2 são dominadas por bandas de absorção de água, as quais mascaram as feições de absorção características de constituintes bioquímicos da vegetação (ASNER, 1998). Por essa razão, a melhor distinção das bandas de absorção de lignina e de celulose (2100 nm e 2300 nm) poderiam ser melhor discriminadas pelo método de remoção do contínuo, principalmente quando os tecidos das plantas encontram-se secos.

## 5.1.2.2 Derivada de 1<sup>a</sup> ordem

Pela análise do atributo derivada de 1<sup>a</sup> ordem tem-se que a maior taxa de variação ocorreu para as fitofisionomias arbóreas, de forma mais acentuada para o período chuvoso (Figura 5.4). Esse fato está associado ao adensamento da vegetação e à

constante presença de água, permitindo a atividade fotossintética plena. Uma vez que a Posição do *Red Edge* (REP) está diretamente associada ao conteúdo de clorofila foliar, podendo ser considerada um indicador de estresse da vegetação (GITELSON et al., 1996; QI et al., 2011), pode-se afirmar que para as fitofisionomias mais densas a variação do conteúdo de clorofila foi mínima. Esse fato pode ser explicado pela maior feição de absorção em 680 nm e pelo ponto de inflexão mais acentuado entre a região espectral do vermelho e do NIR, indicando menor estresse para essas classes de vegetação.

Figura 5.4 Derivada de 1ª ordem dos espectros de reflectância das fitofisionomias Campo Limpo (CL), Campo Limpo com Murundus (CLM), Campo Sujo (CS), Campo Sujo com presença de Arnica e Canela de Ema (CS/A/CE), Campo Cerrado (CC), Campo Cerrado com Trembleias, Cerrado sensu stricto (CSS) e Mata de Galeria (MG) nos períodos chuvoso (a) e seco (b).



Fonte: Produção da autora.

# 5.1.2.3 Índices de vegetação

A resposta sazonal média das fitofisionomias, expressa por seis índices de vegetação de bandas estreitas, está ilustrada na Figura 5.5. Os índices foram escolhidos para representar aspectos estruturais, bioquímicos e fisiológicos da vegetação. Nota-se que os índices NDVI (Figura 5.5 a) e VARI (Figura 5.5 b) apresentaram comportamentos semelhantes para as fitofisionomias CL e CLM limitando, portanto, a discriminação

dessas classes ao longo do período analisado. Como bom estimador de biomassa verde (TUCKER, 1979), o índice NDVI apresentou baixos valores para fitofisionomias campestres e altos valores para fitofisionomias arbóreas, sobretudo para a classe MG. Em média, o NDVI da fitofisionomia MG manteve-se estável ao longo dos meses analisados, devido, principalmente, à estrutura e condições de localização da vegetação, resultando em menor sensibilidade ao déficit hídrico no período seco.

O decaimento dos valores de NDVI, menos acentuado para o período seco, comparado ao índice de vegetação VARI, pode ser explicado pela saturação do NDVI para altos valores de IAF (ROBERTS et al., 2004). O aumento sutil dos valores de NDVI para o mês de agosto pode ser explicado pela variação do índice em relação à geometria de visada do sensor (DEERING et al., 1994).

Diferentemente do índice NDVI, o qual é dependente de fatores como arquitetura do dossel, estrutura celular e inclinação das folhas, o comportamento sazonal do índice VARI pode ser explicado apenas pela reflectância na região espectral do visível, influenciada pela presença de pigmentos fotossintetizantes (GITELSON et al., 2002).

Nota-se, portanto, decaimento mais acentuado do índice VARI no mês de agosto em decorrência do estresse hídrico e da diminuição de pigmentos, sobretudo para as fitofisionomias campestres. Uma vez que o índice VARI é altamente efetivo na estimação de IAF (ROBERTS et al., 2011), o decaimento do índice no período seco pode ser explicado ainda pela diminuição do IAF de algumas espécies devido ao processo de perda das folhas (caducifolia).

Em relação aos índices de vegetação NDII (Figura 5.5 c) e NDWI (Figura 5.5 d), associados ao conteúdo de água foliar, nota-se claro decaimento na direção do período seco. Estudos prévios mostraram que o NDVI também é sensível ao IAF (ROBERTS et al., 2011), o qual diminui do período chuvoso para o seco devido ao mecanismo fenológico de perda das folhas. Os valores de NDII e NDWI para a fitofisionomia MG mantiveram-se praticamente constantes provavelmente devido à quantidade de água nas folhas individuais e à manutenção de umidade no dossel.

O índice RENDVI, associado ao comprimento de onda do *red edge*, demonstrou decaimento no período seco, sobretudo para as fitofisionomias campestres. Esse comportamento pode ser explicado pela associação direta do índice às mudanças na concentração de clorofila sendo, portanto, um indicador sensível ao estresse da vegetação (GITELSON et al., 1996). Já as fitofisionomias CSS e MG mantiveram valores constantes de RENDVI ao longo dos meses por serem fitofisionomias mais densas capazes de manter a atividade fotossintética durante todo o ano.

O PRI é um indicador da eficiência do uso da radiação fotossintética, estando diretamente associado ao processo de dissipação do excesso de energia não utilizada na fotossíntese (GAMON et al., 1997). Na Figura 5.5 f nota-se que, de forma geral, a fitofisionomia MG não apresentou valores superiores de PRI quando comparado a outras fitofisionomias. Esse fato está associado à redução na eficiência do uso da radiação devido ao maior investimento em pigmentos fotoprotetores (GAMON et al., 1997).

Uma vez que a desregulação na eficiência fotoquímica pode ser influenciada pelas condições de estresse da vegetação (SUÁREZ et al., 2008), os menores valores do índice PRI observados para o mês de agosto devem-se ao estresse progressivo da vegetação em relação ao déficit hídrico no período seco (GAMON et al., 1997). A baixa regulação da fotossíntese induzida por fatores como a seca fez com que a vegetação fosse incapaz de utilizar a luz absorvida pela clorofila, resultando em baixos valores desse índice (ROBERTS et al., 2011).

A dificuldade de interpretação sazonal do índice PRI, justifica-se por sua limitação ao estimar a eficiência do uso da radiação fotossintética para amplos intervalos de radiação, que não aquele de Sol a pino (GAMON et al., 1997). Além disso, o estudo de Suárez et al. (2008) relata que a aplicação do índice PRI em larga escala pode ser comprometida devido às diferentes composições de paisagem, arquitetura de dosséis, interferências atmosféricas e efeitos de fundo de solo. Barton e North (2001) revelam ainda que os resultados do índice PRI podem ser altamente influenciados pelo ângulo de visada do sensor e pelos efeitos de iluminação.

Figura 5.5. Comportamento sazonal médio das fitofisionomias do Cerrado expresso pelos IVs NDVI (a), VARI (b), NDII (c), NDWI (d), RENDVI (e) e PRI (f).



Fonte: Produção da autora.

#### 5.1.2.4 Parâmetros de bandas de absorção

A caracterização das fitofisionomias com base na profundidade e área das bandas de absorção, centradas nos comprimentos de onda 680 nm (clorofila) e 1200 nm (água nas folhas), pode ser observada na Figura 5.6. Nota-se que ambos os períodos apresentaram correlações positivas entre as bandas de absorção associadas à clorofila e água nas folhas, sendo que os menores coeficientes de determinação foram observados para o período seco. Essa diferença deve-se ao comportamento distinto entre as fitofisionomias campestres e arbóreas em relação ao déficit hídrico havendo, portanto, uma maior variação nos valores de profundidade e área das bandas de absorção em 680 e 1200 nm.

Uma vez que a métrica profundidade de bandas indica a quantidade do constituinte absorvedor detectado naquele comprimento de onda, quando este atributo não é mascarado pela influência espectral de outros constituintes da planta, pode-se afirmar que maiores quantidades de clorofila e de água nas folhas foram encontradas no período chuvoso. Para esse período foram observadas maiores profundidades das bandas de clorofila e água, não diferindo dos resultados encontrados por Jacon et al. (2017), que indicaram maior atividade fotossintética da vegetação no período chuvoso. Da mesma forma, nota-se a redução na profundidade e área das bandas de absorção no período seco provavelmente em decorrência do estresse hídrico e diminuição da atividade fotossintética da vegetação (GALVÃO et al., 2005).

Figura 5.6 Relação entre profundidades (a) e (b) e áreas (c) e (d) das bandas de absorção de clorofila (680 nm) e de água nas folhas (1200 nm) para as fitofisionomias Campo Limpo (CL), Campo Limpo com Murundus (CLM), Campo Sujo (CS), Campo Sujo com presença de Arnica e Canela de Ema (CS/A/CE), Campo Cerrado (CC), Campo Cerrado com Trembleias, Cerrado *sensu stricto* (CSS) e Mata de Galeria (MG).



Fonte: Produção da autora.

# 5.2 Seleção de atributos e classificação supervisionada após seleção

### 5.2.1 Seleção de atributos usando CFS

A partir do algoritmo de seleção CFS foram selecionados um total de 136 atributos para o período chuvoso e 93 para o período seco (Tabela 5.2), já desconsiderando os atributos característicos de bandas ruidosas. Observa-se que o número de atributos selecionados no período seco foi menor que o número de atributos selecionados no período chuvoso, estando de acordo com os resultados encontrados no estudo de Jacon et al. (2017).

O presente estudo mostrou que a discriminação das fitofisionomias do PNB não foi comprometida no período chuvoso, já que para esse período foi selecionado maior número de atributos pelo algoritmo CFS, compensando, dessa forma, as confusões espectrais decorrentes do maior vigor da vegetação durante esse período.

Em relação ao atributo reflectância, foram selecionadas 38 bandas espectrais no período chuvoso e 18 bandas no período seco. Esses resultados assemelham-se aos encontrados por Jacon et al. (2017), em que foram selecionadas 26 bandas no período chuvoso e 22 no período seco por meio do método passo-a-passo de Análise Discriminante Múltipla (MDA). Já para o atributo derivada de 1ª ordem foram selecionadas 23 bandas os períodos chuvoso e seco havendo, no entanto, poucas bandas em comum para ambos os períodos.

Quanto ao atributo parâmetros de bandas de absorção, foram selecionados 5 parâmetros para o período chuvoso, enquanto que para o período seco apenas 2 tiveram relevância. Pela Tabela 5.2 observa-se que o parâmetro área em 1200 nm, relacionado ao conteúdo de água nas folhas (GALVÃO et al., 2005), foi selecionado apenas para o período chuvoso, coincidindo ao encontrado por Jacon et al. (2017), que utilizaram os mesmos parâmetros de bandas de absorção. No presente estudo apenas os parâmetros área em 680 nm e profundidade em 680 nm foram comuns a ambos os períodos, não diferindo dos resultados encontrados por Jacon et al. (2017).

Considerando os mesmos índices de vegetação utilizados no estudo de Jacon et al. (2017), notam-se pequenas diferenças quanto à seleção desse atributo nos períodos chuvoso e seco. No presente estudo foram selecionados no total 14 índices para os dois períodos, sendo 10 IVs comuns a ambos. Já no estudo de Jacon et al. (2017) foram selecionados pelo método passo-a-passo 12 índices de vegetação, sendo que 10 foram selecionados no período chuvoso e 9 no período seco.

		Janeiro					Junho		
		Parâmetros	ć				Parâmetros	ć	
Reflectância	Derivada de	de bandas	Indices de	Todos os	Reflectância	Derivada de	de bandas	Indices de	Todos os
	1° ordem	de absorção	Vegetação	atributos		1° ordem	de absorção	Vegetação	atributos
467 nm	PD 487 nm	(A) 680 nm	NDVI	(P) 680 nm	457 nm	PD 559 nm	(A) 680 nm	NDVI	(A) 680 nm
477 nm	PD 579 nm	(P) 680 nm	VARI	(A) 1200 nm	498 nm	PD 599 nm	(P) 680 nm	EVI	(P) 680 nm
487 nm	PD 589 nm	(L) 680 nm	NDII	NDVI	640 nm	PD 650 nm		Vlg	(L) 680 nm
498 nm	PD 599 nm	(A)2300 nm	SIPI	EVI	650 nm	PD 671 nm		VARI	NDVI
508 nm	PD 660 nm	(A) 1200 nm	NDWI	NDII	660 nm	PD 691 nm		MSI	EVI
538 nm	PD 681 nm		WBI	SIPI	671 nm	PD 701 nm		NDII	Vlg
548 nm	PD 701 nm		PSRI	NDWI	681 nm	PD 711 nm		NDWI	VARI
559 nm	PD 711 nm		MCARI	MCARI	691 nm	PD 721 nm		PSSR	MSI
579 nm	PD 721 nm		ARI	ARI	701 nm	PD 732 nm		PSRI	NDII
599 nm	PD 732 nm		LWVI2	CRI1	732 nm	PD 1083 nm		MCARI	SIPI
671 nm	PD 752 nm		REPI	REPI	772 nm	PD 1094 nm		ARI	NDWI
681 nm	PD 905 nm		VOG	VOG	833 nm	PD 1164 nm		VOG	PSSR
691 nm	PD 1124 nm		RENDVI	PRI	1517 nm	PD 1174 nm		RENDVI	MCARI
701 nm	PD 1295 nm		RVSI	PD 599 nm	1537 nm	PD 1336 nm		RVSI	ARI
711 nm	PD 1598 nm			PD 660 nm	2143 nm	PD 1507 nm			LWVI2
721 nm	PD 1608 nm			PD 691 nm	2183 nm	PD 1558 nm			VOG
732 nm	PD 1618 nm			PD 701 nm	2203 nm	PD 1669 nm			RENDVI
742 nm	PD 1648 nm			PD 711 nm	2224 nm	PD 1719 nm			PD 559
752 nm	PD 1719 nm			PD 721 nm		PD 1739 nm			PD 589
762 nm	PD 1769 nm			PD 742 nm		PD 1759 nm			PD 711
772 nm	PD 2062 nm			PD 752 nm		PD 1/69 nm			PD 721
833 nm	PD 2213 nm			PD 762 nm		PD 21/3 nm			PD 752
864 nm	PD 2244 nm			PD 813 nm		PD 2234 nm			PD 772
1033 nm				PD 8/4 nm					PD 813
1094 nm				PD 884 nm					PD 1719
1255 nm				PD 905 nm					457
1275 nm				PD 1104 nm					650
1689 nm				PD 1336 nm					591
1729 mm				477 nm					701
2072 nm				477 mm					711
2072 IIII 2152 nm				407 mm					721
2102 nm				508 nm					732
2193 mm				518 nm					1517
2203 mm				538 nm					1537
2254 nm				548 nm					1659
2304 nm				559 nm					1055
2314 nm				579 nm					
20211111				599 nm					
				671 nm					
				711 nm					
				721 nm					
				742 nm					
				762 nm					
				772 nm					
				1094 nm					
				1255 nm					
				1275 nm					
				1689 nm					
				1729 nm					
				1759 nm					
				2072 nm					
				2203 nm					
				2234 nm					
				2254 nm					
				2314 nm					

Tabela 5.2 Seleção de atributos realizada pelo algoritmo CFS.

(A), (P), (L) e PD significam, respectivamente, área, profundidade, largura e Derivada de 1ªordem.

Fonte: produção da autora.

Na análise de todos os atributos em conjunto, neste estudo foram selecionados 56 atributos para o período chuvoso e 36 para o período seco. A maior quantidade de atributos selecionados no período chuvoso está de acordo com os resultados obtidos por Jacon et al. (2017), em que 33 atributos hiperespectrais foram selecionados no período chuvoso e 28 no período seco.

A alta dimensionalidade dos dados hiperespectrais pode ser observada pela Figura 5.7, que mostra a correlação entre todos os atributos nos períodos chuvoso e seco. Diante disso, o algoritmo de seleção CFS desempenhou papel relevante na exclusão dos atributos altamente correlacionados entre si, mantendo aqueles correlacionados às classes de vegetação, de forma a contribuir para o processo de identificação das fitofisionomias.

Figura 5.7. Matrizes de correlação entre todos os atributos analisados nos períodos chuvoso e seco, antes da seleção de atributos.



Fonte: Produção da autora.

#### 5.2.2 Avaliação de desempenho das classificações nos períodos chuvoso e seco

As classificações do período chuvoso apresentaram porcentagens de exatidão total ligeiramente superiores às do período seco. Os maiores valores de exatidão total e de índice Kappa, associados ao atributo reflectância, ocorreram para o algoritmo de

classificação SVM (Tabela 5.3), que apresentou exatidão de 79,59% no período chuvoso e 74,34% no período seco.

Figura 5.8 Classificações das fitofisionomias a partir do atributo reflectância nos períodos chuvoso (Janeiro) e seco (Junho). O mapa de referência foi adaptado de Ferreira (2003a).



Fonte: Produção da autora.

Pelas matrizes de confusão apresentadas no Apêndice A, nota-se que, para o atributo reflectância, os maiores erros de omissão (71,31%) e inclusão (77,13%) foram atribuídos ao algoritmo SAM, em relação à fitofisionomia CLM, no período seco (Tabela A.1b). Em relação ao número de *pixels* classificados, nota-se uma confusão entre as classes CLM e CL, uma vez que 56 *pixels* da fitofisionomia CLM foram classificados como CL, enquanto que apenas 35 *pixels* foram classificados corretamente como CLM.

<u>(</u> ]			(	Classific	ação - J	aneiro			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	151	0	0	0	22	0	10	0	183	82.51	17.49
ССТ	0	47	2	1	4	7	0	1	62	75.81	24.19
CL	1	2	103	26	8	0	0	0	140	73.57	26.43
CLM	0	3	44	69	6	0	0	0	122	56.56	43.44
CS	30	0	13	4	127	0	1	0	175	72.57	27.43
CS/A/CE	0	0	1	2	8	45	0	0	56	80.36	19.64
CSS	17	0	0	0	0	0	168	2	187	89.84	10.16
MG	1	0	0	0	0	0	2	140	143	97.9	2.1
Total (pixels)	200	52	163	102	175	52	181	143	1068		
Exatidão do usuário (%)	75.5	90.38	63.19	67.65	72.57	86.54	92.82	97.9		Exatidão total:	79.59%
Erros de inclusão (%)	24.5	9.62	36.81	32.35	27.43	13.46	7.18	2.1		Índice Kappa:	0.76

Tabela 5.3 Matriz de confusão da classificação SVM, no período chuvoso, para o atributo reflectância e o conjunto separado de *pixels* de validação.

A respeito do atributo derivada de 1ª ordem, as classificações que apresentaram maior exatidão total estiveram associadas ao algoritmo de classificação RF (Figura 5.9). A maior exatidão ocorreu para o período chuvoso, com 76,31% de acertos e índice Kappa igual a 0,72 (Tabela 5.4), enquanto que o período seco apresentou exatidão total de 60,49%.

O maior erro de omissão (98,15%) para esse atributo ocorreu para a classificação SVM em relação à fitofisionomia CCT, no período seco (Tabela A.7b). Tendo em vista que a maioria dos *pixels* da classe CCT foi classificada como CSS, observa-se maior confusão em relação a essa classe. O maior erro de inclusão (87,03%), associado ao algoritmo SAM, ocorreu para a fitofisionomia CS/A/CE, no período chuvoso, sendo que a maior confusão ocorreu em relação à fitofisionomia CSS (Tabela A.5a). Para ambos os períodos, os menores valores de exatidão total ocorreram para o algoritmo SAM, sendo 23,97% de acertos para o período chuvoso e 40,92% para o período seco.

Figura 5.9 Classificações das fitofisionomias a partir do atributo derivada de 1ª ordem nos períodos chuvoso (Janeiro) e seco (Junho). O mapa de referência foi adaptado de Ferreira (2003a).



Fonte: Produção da autora.

Em relação às classificações referentes ao atributo índice de vegetação (Figura 5.10), aquela que obteve os maiores valores de exatidão total e índice Kappa (0,75) foi a classificação associada ao algoritmo RF (Tabela 5.5). A exatidão total para o período chuvoso foi de 79,4%, enquanto que para o período seco a exatidão obtida foi de 75,37%.

O maior erro de omissão (73,77%) ocorreu para a fitofisionomia CLM, em relação ao algoritmo de classificação SAM, no período seco (Tabela 4.9b), sendo que a maior confusão ocorreu em relação à classe CL. Em relação aos erros de inclusão, a fitofisionomia que apresentou maior percentual (74,45%) foi a fitofisionomia CCT, associada ao algoritmo de classificação SAM, no período chuvoso (Tabela 4.9a). Para essa classe, a maior confusão ocorreu em relação á fitofisionomia CC.

Classes	_		0	lassifica	ição - J	aneiro			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
СС	134	0	3	0	17	1	28	0	183	73.22	26.78
ССТ	2	46	5	2	4	0	1	2	62	74.19	25.81
CL	2	0	118	17	3	0	0	0	140	84.29	15.71
CLM	3	0	46	57	12	1	2	1	122	46.72	53.28
CS	12	1	17	8	135	1	1	0	175	77.14	22.86
CS/A/CE	3	1	0	1	2	47	1	1	56	83.93	16.07
CSS	19	0	0	1	18	0	145	4	187	77.54	22.46
MG	0	0	0	0	2	0	8	133	143	93.01	6.99
Total (pixels)	175	48	189	86	193	50	186	141	1068		
Exatidão do usuário (%)	76.57	95.83	62.43	66.28	69.95	94	77.96	94.33		Exatidão total:	76.31%
Erros de inclusão (%)	23.43	4.17	37.57	33.72	30.05	6	22.04	5.67		Índice Kappa:	0.72

Tabela 5.4 Matriz de confusão da classificação RF, no período chuvoso, para o atributo derivada de 1ª ordem e o conjunto separado de *pixels* de validação.

Figura 5.10 Classificações das fitofisionomias a partir do atributo índice de vegetação nos períodos chuvoso (Janeiro) e seco (Junho). O mapa de referência foi adaptado de Ferreira (2003a).



Fonte: Produção da autora.

Classes			С	lassificaç	ção - Ja	neiro			Total	Exatidão do	Erros de
Classes	CC	CCT	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	154	0	0	0	21	0	8	0	183	84.15	15.85
ССТ	0	42	6	6	5	1	0	2	62	67.74	32.26
CL	4	0	103	26	7	0	0	0	140	73.57	26.43
CLM	1	0	51	62	7	1	0	0	122	50.81	49.19
CS	15	1	12	5	141	0	1	0	175	80.57	19.43
CS/A/CE	1	4	0	0	4	47	0	0	56	83.92	16.08
CSS	21	0	0	2	2	0	160	2	187	85.56	14.44
MG	1	0	0	0	0	0	3	139	143	97.2	2.8
Total (pixels)	197	47	172	101	187	49	172	143	1068		
Exatidão do usuário (%)	78.17	89.36	59.88	61.39	75.4	95.92	93.92	97.2		Exatidão total:	79.40%
Erros de inclusão (%)	21.83	10.64	40.12	38.61	24.6	4.08	6.08	2.8		Índice Kappa:	0.75

Tabela 5.5 Matriz de confusão da classificação RF, no período chuvoso, para o atributo índice de vegetação e para o conjunto separado de *pixels* de validação.

As classificações referentes ao atributo parâmetros de bandas de absorção (Figura 5.11) foram as que apresentaram menores percentuais de acerto provavelmente em decorrência dos ruídos em destaque. Dois algoritmos de classificação se destacaram em relação à exatidão total: o algoritmo RF para o período chuvoso, com exatidão total de 63,67% e índice Kappa de 0,57 (Tabela 5.6) e o algoritmo J48, o qual proporcionou um percentual de acerto de 58,24% para o período seco. As menores exatidões totais ocorreram para o algoritmo de classificação SAM em ambos os períodos.

Os maiores percentuais de erros de omissão (98,39%) e inclusão (93,73%) foram atribuídos ao algoritmo de classificação SAM no período chuvoso (Tabela A.13a). O maior erro de omissão foi conferido à fitofisionomia CCT, que apresentou confusão com a fitofisionomia MG. Já o maior erro de inclusão ocorreu para a classe CS/A/CE, que também apresentou confusão em relação à classe MG.

Figura 5.11 Classificações das fitofisionomias a partir do atributo parâmetro de bandas de absorção nos períodos chuvoso (Janeiro) e seco (Junho). O mapa de referência foi adaptado de Ferreira (2003a).



Fonte: Produção da autora.

Tabela 5.6 Matriz de confusão da classificação RF, no período chuvoso, para o atributo parâmetros de bandas de absorção e para o conjunto separado de *pixels* de validação.

Classes			C	lassificaç	ão - Ja	neiro			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	102	9	2	0	54	1	15	0	183	55.74	44.26
ССТ	11	12	9	8	19	1	1	1	62	19.35	80.65
CL	1	3	83	40	12	1	0	0	140	59.29	40.71
CLM	3	2	46	60	11	0	0	0	122	49.18	50.82
CS	30	16	13	10	99	4	3	0	175	56.57	43.43
CS/A/CE	3	1	5	10	3	33	1	0	56	58.93	41.07
CSS	24	6	0	0	3	0	152	2	187	81.28	18.72
MG	1	0	0	0	0	0	3	139	143	97.2	2.8
Total (pixels)	175	49	158	128	201	40	175	142	1068		
Exatidão do usuário (%)	58.29	24.49	52.53	46.88	49.25	82.5	86.86	97.89		Exatidão total:	63.67%
Erros de inclusão (%)	41.71	75.51	47.47	53.12	50.75	17.5	13.14	2.11		Índice Kappa:	0.57

Em relação às classificações de todos os atributos em conjunto (Figura 5.12), a maior exatidão total foi conferida ao algoritmo SVM, tanto para o período chuvoso (84,18%)

quanto para o período seco (82,02%). O algoritmo SAM, apresentou os menores percentuais de acerto para ambos os períodos. Considerando-se as classificações de todos os atributos em conjunto, aquela que apresentou maior valor de índice Kappa (0,81) foi a classificação SVM, no período chuvoso (Tabela 5.7).

Tabela 5.7 Matriz de confusão da classificação SVM, no período chuvoso, para todos os atributos em conjunto e para o conjunto separado de *pixels* de validação.

Classes			Cl	assificaç	ão - Jar	neiro			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	151	0	0	0	18	0	14	0	183	82.51	17.49
ССТ	0	54	2	2	3	0	0	1	62	87.1	12.9
CL	3	1	106	29	1	0	0	0	140	75.71	24.29
CLM	0	0	33	82	7	0	0	0	122	67.21	32.79
CS	15	0	9	3	148	0	0	0	175	84.57	15.43
CS/A/CE	2	2	0	0	4	48	0	0	56	85.71	14.29
CSS	16	0	0	0	0	0	170	1	187	90.91	9.09
MG	0	0	0	0	0	0	3	140	143	97.9	2.1
Total (pixels)	187	57	150	116	181	48	187	142	1068		
Exatidão do usuário (%)	80.75	94.74	70.67	70.69	81.77	100	90.91	98.59		Exatidão total:	84.18%
Erros de inclusão (%)	19.25	5.26	29.33	29.31	18.23	0	9.09	1.41		Índice Kappa:	0.81

Fonte: Produção da autora.

Os maiores erros de omissão (84,57%) e inclusão (86,25%) foram atribuídos ao classificador SAM, em relação ao período chuvoso (Tabela A.17a). O maior erro de omissão foi atribuído à fitofisionomia CS, que apresentou confusão em relação à fitofisionomia CSS. A maior porcentagem de erro de inclusão ocorreu para a classe CCT, havendo maior confusão em relação à classe CC.

Figura 5.12 Classificações das fitofisionomias a partir de todos os atributos nos períodos chuvoso (Janeiro) e seco (Junho). O mapa de referência foi adaptado de Ferreira (2003a).



Fonte: Produção da autora.

Com base nos resultados apresentados pode-se afirmar que os maiores valores de exatidão total e índice Kappa foram atribuídos às classificações de todos os atributos em conjunto, não diferindo dos resultados apresentados por Jacon et al. (2017). As menores exatidões foram associadas aos atributos parâmetros de bandas de absorção e derivada de 1ª ordem, conforme apresentado na Tabela 5.8. As matrizes de confusão (Apêndice A) mostraram que, para todos os atributos testados, as mais robustas classificações estiveram associadas aos algoritmos de classificação RF e SVM, em relação ao período chuvoso.

			Perí	odo Ch	uvoso				Período Seco							
Atributos	J4	18	R	F	SV	Μ	SA	M	$\mathbf{J}_{\mathbf{J}}$	18	R	F	SV	М	SA	Μ
	E.T. (%)	Kappa	E.T. (%)	Kappa	E.T. (%)	Kappa	E.T. (%)	Kappa	E.T. (%)	Kappa	E.T. (%)	Kappa	E.T. (%)	Kappa	E.T. (%)	Kappa
Reflectância	71.54	0.66	78.84	0.75	79.59	0.76	62.45	0.56	68.07	0.62	73.5	0.68	74.34	0.69	54.59	0.47
Derivada de 1º ordem	63.39	0.57	76.31	0.72	70.79	0.65	23.97	0.13	47.75	0.38	60.49	0.53	57.12	0.49	40.92	0.32
Parâmetros de bandas de absorcão	59.64	0.52	63.67	0.57	60.30	0.53	17.98	0.07	58.24	0.5	50.37	0.41	57.4	0.49	26.5	0.16
Índices de Vegetação	72.00	0.67	79.40	0.75	79.31	0.75	57.49	0.50	66.39	0.6	75.37	0.71	74.72	0.70	53.28	0.46
Todos os atributos	71.82	0.67	83.24	0.80	84.18	0.81	37.08	0.27	67.23	0.61	81.46	0.78	82.02	0.78	52.06	0.44

Tabela 5.8. Exatidão total (E.T.) e índice Kappa dos algoritmos de classificação em relação aos atributos selecionados.

Os percentuais de erros de omissão e inclusão estão representados pela Tabela 5.9 e Tabela 5.10, respectivamente. Pelas tabelas observa-se que os menores erros de omissão ocorreram para o classificador RF, em relação à fitofisionomia MG, no período chuvoso. Os maiores erros de omissão, por sua vez, ocorreram para o algoritmo SAM, em relação às fitofisionomias CLM e CCT, no período seco.

Tabela 5.9 Visão geral dos erros de omissão das classificações em relação aos atributos selecionados.

	Erros de omissão												
A 4- h-4 a a	Me	nor percentual		Ma	ior percentual								
Atributos	Classificador	Fitofisionomia	Período	Classificador	Fitofisionomia	Período							
Reflectância	RF	MG	chuvoso	SAM	CLM	seco							
Derivada de $1^\circ$ ordem	RF	MG	chuvoso	SVM	CCT	seco							
Índices de Vegetação	SVM e RF	MG	chuvoso	SAM	CLM	seco							
Parâmetros de bandas de absorção	RF	MG	chuvoso	SAM	CCT	chuvoso							
Todos os atributos	RF	MG	chuvoso	SAM	CS/A/CE	chuvoso							

Fonte: Produção da autora.

Já em relação ao erro de inclusão, os menores percentuais foram atribuídos ao algoritmo SVM, para a fitofisionomia MG, no período seco. Os maiores erros de inclusão foram conferidos ao classificador SAM, em relação às fitofisionomias CS e CCT, no período chuvoso.

Tratando-se deste estudo, o período seco não foi necessariamente melhor do que o chuvoso para a distinção das fitofisionomias de Cerrado, mesmo que as diferenças

estruturais da vegetação sejam mais perceptíveis em decorrência da abertura do dossel com o déficit hídrico e da maior quantidade de biomassa seca na copa das árvores e no substrato. A maior confusão espectral no período chuvoso pode ter sido compensada pela seleção de um maior número de atributos para fins de classificação, quando comparado com o período seco. Sobre a média decenal, janeiro de 2015 foi um mês atípico, com uma quantidade de chuvas bem menor do que a esperada (Figura 3.2). Em 2015, o pico de precipitação ocorreu em março, ao contrário do normalmente observado em janeiro e fevereiro, o que pôde também ter influenciado nos resultados.

Erros de inclusão												
Atributos	Me	nor percentual		Mai	or percentual							
Atributos	Classificador	Fitofisionomia	Período	Classificador	Fitofisionomia	Período						
Reflectância	SVM	MG	seco	SAM	CLM	seco						
Derivada de 1º ordem	SVM	MG	chuvoso	SAM	CS	chuvoso						
Índices de Vegetação	RF	MG	seco	SAM	CCT	chuvoso						
Parâmetros de bandas de absorção	SVM	MG	seco	SAM	CS	chuvoso						
Todos os atributos	SVM	CS/A/CE	chuvoso	SAM	ССТ	chuvoso						

Tabela 5.10 Visão geral dos erros de omissão das classificações em relação aos atributos selecionados.

Fonte: Produção da autora.

Pela Figura 5.13 observa-se que os ganhos obtidos nas classificações do período seco restringiram-se apenas a três atributos: derivada de 1ª ordem, parâmetros de bandas de absorção e todos os atributos em conjunto, associados ao algoritmo de classificação SAM. Além da atipicidade do regime de chuvas de 2015, a ausência de ganho para as demais classificações pode ser explicada pela diferença na geometria da aquisição das imagens de janeiro e junho, já que a cena do período chuvoso foi imageada sob um ângulo zenital solar menor em relação ao período seco e com grau de apontamento do sensor elevado em ambos.

O ganho de alguns atributos na classificação SAM pode ser explicado pelo fato desse algoritmo não ser influenciado pelas condições de iluminação, já que o ângulo formado entre os dois vetores é independente do comprimento do vetor (KRUSE et al., 1993). Para o classificador SAM, a exatidão total obtida pelo atributo derivada de 1<sup>a</sup> ordem foi de 23,97% para o período chuvoso e 40,92% para o período seco, resultando num ganho de 70,70%. O atributo parâmetros de bandas de absorção obteve ganho de 47,39% no período seco, uma vez que as exatidões totais dos períodos chuvoso e seco foram 17,98% e 26,50%, respectivamente. Em relação à análise de todos os atributos em conjunto, a exatidão obtida no período chuvoso foi de 37,08%, enquanto que para o período seco foi de 52,06%. O ganho conferido a esse atributo foi de 40,40%.

Figura 5.13 Ganhos obtidos nas classificações do período chuvoso para o seco em relação aos atributos selecionados.



Fonte: Produção da autora.

Os resultados do presente estudo foram comparados aos dados obtidos por Jacon et al. (2017), em relação às classificações das fitofisionomias da Estação Ecológica de Águas Emendadas, distante 50 km do PNB, usando Análise Discriminante Múltipla (MDA) passo-a-passo. No presente estudo tem-se que os atributos índice de vegetação, parâmetros de bandas de absorção e todos os atributos em conjunto não obtiveram ganhos na classificação do período seco, diferindo dos resultados apresentados por Jacon et al. (2017), provavelmente devido às diferenças de geometria de visada do sensor e às diferentes espécies abordadas neste estudo.

No que diz respeito aos resultados de classificação para o período chuvoso, pode-se dizer que a maior confusão espectral foi compensada pela inserção de um maior número de atributos selecionados nesse período, especialmente em relação aos

atributos reflectância, parâmetros de bandas de absorção e ao conjunto total de atributos (Tabela 5.2), ou ainda pela atipicidade de ocorrências de chuvas, que não foram tão frequentes no ano de 2015.

Os ganhos associados às fitofisionomias classificadas foram ilustrados pela Figura 5.14, em que estão representadas as exatidões do usuário para cada classe em relação a todos os atributos em conjunto, para ambos os períodos. De forma geral, os ganhos mais expressivos para as classificações do período chuvoso estiveram associados às fitofisionomias CS/A/CE e CCT (espécie invasora). Para a classificação SVM os ganhos foram de 26,31% e 26,32%, respectivamente, enquanto que para a classificação J48 os ganhos foram de 46,64% para CS/A/CE e 16,67% para CCT. Por fim, em relação ao algoritmo de classificação RF, os ganhos obtidos foram de 28,35% e 18,73%, nessa ordem.

Figura 5.14 Exatidões do usuário para as fitofisionomias classificadas no período chuvoso e seco utilizando todos os atributos em conjunto.



Fonte: Produção da autora.

Optou-se ainda por representar as exatidões das fitofisionomias classificadas pelo algoritmo RF para os demais atributos (Figura 5.15). De maneira geral, as maiores exatidões do produtor e do usuário ocorreram no período chuvoso.

Figura 5.15 Exatidão do produtor e do usuário para as fitofisionomias classificadas pelo algoritmo RF, no período chuvoso e seco, considerando-se todos os atributos individualmente.



Observa-se também que os menores valores de exatidão do produtor e do usuário ocorreram para o atributo parâmetros de bandas de absorção, no período chuvoso, enquanto que, para o período seco, os menores valores foram atribuídos aos atributos derivada de 1ª ordem e parâmetros de bandas de absorção. Sob uma visão geral, as fitofisionomias classificadas pelo atributo parâmetros de bandas de absorção apresentaram as menores exatidões do produtor e do usuário, tanto no período chuvoso quanto no período seco.

Ao considerar o algoritmo de classificação RF, novas exatidões totais e índices Kappa (Tabela 5.11) foram obtidos a partir da exclusão das fitofisionomias CLM, CCT e CS/A/CE. Para ambos os períodos se observa que em todos os atributos houve aumento da exatidão total e índice Kappa em relação à classificação RF em que as fitofisionomias CLM, CCT e CS/A/CE foram desconsideradas. Esse comportamento

deve-se à menor variabilidade espectral entre as classes, o que pode contribuir para a melhor separabilidade por parte do classificador.

De maneira geral, as exatidões totais obtidas no período chuvoso foram maiores que as obtidas no período seco, exceto para todos os atributos analisados em conjunto. Observa-se que a exclusão das fitofisionomias CLM, CCT e CS/A/CE resultou em ganhos para ambos os períodos, porém, os maiores ganhos ocorreram para o período seco em relação ao período chuvoso.

Tabela 5.11 Exatidão total, ganho e índice Kappa das classificações RF sem a inclusão das fitofisionomias Campo Limpo com Murundus (CLM), Campo Cerrado com Trembleias (CCT) e Campo Sujo com presença de Arnica e Canela de Ema (CS/A/CE).

A 4	Período	chuvoso		Perío	do seco	
Atributos	Exatidão total (%)	Ganho (%)	Карра	Exatidão total (%)	Ganho (%)	Карра
Reflectância	86.83	9.20	0.83	84.26	12.77	0.80
Derivada de 1° ordem	82.72	7.75	0.78	72.18	16.20	0.65
Parâmetros de bandas de absorção	77.41	17.75	0.71	69.70	27.73	0.62
Índices de Vegetação	86.47	8.18	0.83	84.61	10.92	0.80
Todos os atributos	88.76	6.22	0.85	89.34	8.82	0.86

Fonte: Produção da autora.

# 5.2.3 Quantificação das incertezas por meio da entropia de Shannon

A quantificação das incertezas para cada atributo hiperespectral foi feita pelo cálculo da entropia de Shannon, em que cada *pixel* classificado foi avaliado em relação à regra de decisão dos diferentes algoritmos de classificação. Pela Figura 5.16 nota-se que os valores da entropia de Shannon variaram de 0 a 0,7 para ambos os períodos, chuvoso e seco.



Figura 5.16 Mapas de incerteza dos atributos hiperespectrais quantificados por meio da entropia de Shannon.

Fonte: Produção da autora.

Dentre os atributos analisados, observa-se que os altos valores de entropia ocorreram em maior extensão para os atributos derivada de 1ª ordem e parâmetros de bandas de absorção em função da baixa relação sinal/ruído do Hyperion e do realce de feições espúrias por essas técnicas. Esse comportamento foi coerente com as menores exatidões totais obtidas nas classificações a partir desses atributos.

Associados aos mapas de incerteza da entropia estão os mapas referentes às modas, que foram comparados com o mapa de referência (Figura 5.17). Esses mapas indicam, para cada *pixel* analisado, a fitofisionomia que mais vezes foi classificada segundo a regra de decisão de cada classificador. Pela representatividade da moda pode-se

concluir a respeito de qual fitofisionomia contribuiu para os maiores ou menores valores nos mapas de entropia.



Figura 5.17 Mapas representativos da moda para cada um dos *pixels* avaliados.

Fonte: Produção da autora.

Em geral, os mapas de moda mostraram concordância com os mapas de entropia, principalmente em relação às fitofisionomias campestres. Pelo mapa de moda nota-se uma maior confusão na discriminação das fitofisionomias CL e CCT, as quais também foram consideradas como CC, CLM e CS pelas regras de decisão dos classificadores, devido à similaridade espectral entre essas fitofisionomias.

Os menores valores de entropia (0-0,300) ocorreram para as fitofisionomias CSS e MG, demonstrando baixa confusão quanto às regras de decisão dos classificadores. A ocorrência de tais fitofisionomias nos mapas de moda demonstrou concordância em relação ao mapa de referência.

De forma geral, tem-se que as classificações referentes aos atributos reflectância, índices de vegetação e todos os atributos em conjunto obtiveram as menores incertezas

em relação às regras de decisão dos algoritmos de classificação. No que diz respeito às fitofisionomias classificadas, as maiores confusões ocorreram para as fitofisionomias campestres, enquanto que as fitofisionomias arbóreas, como CSS e MG, apresentaram maior concordância entre os classificadores.

# 5.3 Análise estatística por meio de técnicas de simulação estocástica

O desempenho das classificações foi avaliado por meio das Funções de Distribuição de Probabilidade (FDP) do índice Kappa, obtidas mediante o processo de simulação estocástica. As métricas estatísticas associadas às FDPs estão listadas na Tabela 5.12. Pelas métricas estatísticas observa-se que os valores de maior frequência (moda) apresentaram-se bem próximos aos valores de média e mediana, o que aproxima a distribuição dos índices Kappa a uma distribuição normal.

				Métricas e	statístic	cas	
Classificador	Atributo	Mé	dia	Medi	iana	Mo	da
		Jan	Jun	Jan	Jun	Jan	Jun
	Reflectância	0.688	0.532	0.688	0.531	0.683	0.530
	Derivada de 1° ordem	0.072	0.301	0.071	0.301	0.067	0.292
SAM	Parâmetros de bandas de absorção	0.045	0.145	0.045	0.145	0.028	0.138
	Índices de vegetação	0.587	0.570	0.586	0.570	0.595	0.558
	Todos os atributos	0.331	0.554	0.331	0.554	0.311	0.558
	Reflectância	0.761	0.679	0.763	0.679	0.735	0.665
	Derivada de 1° ordem	0.657	0.476	0.659	0.476	0.651	0.464
SVM	Parâmetros de bandas de absorção	0.531	0.469	0.530	0.467	0.521	0.471
	Índices de vegetação	0.756	0.678	0.758	0.678	0.744	0.683
	Todos os atributos	0.813	0.764	0.814	0.763	0.824	0.749
	Reflectância	0.668	0.615	0.667	0.615	0.670	0.623
	Derivada de 1° ordem	0.573	0.370	0.573	0.370	0.605	0.357
J48	Parâmetros de bandas de absorção	0.527	0.483	0.527	0.483	0.512	0.483
	Índices de vegetação	0.674	0.586	0.675	0.586	0.661	0.572
	Todos os atributos	0.673	0.600	0.675	0.600	0.684	0.581
	Reflectância	0.752	0.672	0.754	0.673	0.754	0.697
	Derivada de 1° ordem	0.724	0.515	0.725	0.514	0.707	0.490
RF J	Parâmetros de bandas de absorção	0.573	0.397	0.573	0.398	0.573	0.376
	Índices de vegetação	0.759	0.690	0.758	0.689	0.763	0.684
	Todos os atributos	0.803	0.759	0.805	0.758	0.819	0.758

Tabela 5.12 Métricas estatísticas das distribuições dos índices Kappa, geradas para cada classificação nos períodos chuvoso e seco.

Fonte: Produção da autora.

A Tabela 5.13 apresenta o ordenamento das médias de índice Kappa das classificações. De forma geral, nota-se que as classificações do período chuvoso obtiveram desempenho ligeiramente superior em relação às classificações do período seco, exceto para os atributos associados ao algoritmo de classificação SAM. Os menores valores de média do índice Kappa ocorreram para o atributo parâmetros de bandas de absorção, nos períodos chuvoso e seco. Conforme o esperado, os algoritmos de classificação SVM e RF alcançaram as maiores média de índice Kappa para ambos os períodos avaliados.

Janeiro Junho Posição Classificador Kappa (Média) Classificador Kappa (Média) Atributo Atributo 1º SVM Todos os atributos 0.813 SVM 0.764 Todos os atributos 2° 0.803 0.759 RF Todos os atributos RF Todos os atributos 3° SVM Reflectância 0.761 RF Índices de vegetação 0.690 4° 0.759 SVM RF Índices de vegetação Reflectância 0.679 5° SVM Índices de vegetação 0.756 SVM Índices de vegetação 0.678 6° RF RF Reflectância 0.672 Reflectância 0.752 7° RF Derivada de 1º ordem 0.724 I48 Reflectância 0.615 8° SAM Reflectância 0.688 J48 Todos os atributos 0.600 9º J48 0.674 J48 Índices de vegetação 0.586 Índices de vegetação 10° I48 Todos os atributos 0.673 SAM Índices de vegetação 0.570 Reflectância 11° J48 0.668 SAM Todos os atributos 0.554 12° SVM Derivada de 1º ordem 0.657 SAM Reflectância 0.532 130 SAM 0 587 0 5 1 5 Índices de vegetação RF Derivada de 1º ordem 14° RF Parâmetros de bandas de absorção 0.573 J48 Parâmetros de bandas de absorção 0.483 15° J48 Derivada de 1º ordem 0.573 SVM Derivada de 1º ordem 0.476 SVM 16° Parâmetros de bandas de absorcão 0.531 SVM Parâmetros de bandas de absorção 0.469 Parâmetros de bandas de absorção 17° I48 Parâmetros de bandas de absorção 0.527 RF 0 3 9 7 18° SAM Todos os atributos 0.331 J48 Derivada de 1º ordem 0.370 19° SAM Derivada de 1º ordem 0.072 SAM Derivada de 1º ordem 0.301 20° SAM Parâmetros de bandas de absorcão 0.045 SAM Parâmetros de bandas de absorção 0.145

Tabela 5.13 Média do índice Kappa para as classificações dos períodos chuvoso e seco.

Fonte: Produção da autora.

O gráfico *boxplot* (Figura 5.18) das FDPs das diferenças dos valores de Kappa teve como objetivo avaliar se as classificações dos períodos chuvoso e seco apresentaram diferenças significativas entre si. Considerando o intervalo de credibilidade de 99% pode-se afirmar que não houve diferença estatística entre os períodos seco e chuvoso para a maioria das classificações. Aquelas que apresentaram diferença significativa estiveram associadas ao atributo derivada de 1ª ordem e ao algoritmo de classificação SAM.

A não rejeição da hipótese nula pela maioria dos atributos reflectância, parâmetros de bandas de absorção e todos os atributos em conjunto, justifica-se pela maior seleção desses atributos no período chuvoso, comparado ao período seco. Como dito anteriormente, a confusão espectral associada ao período chuvoso pode ter sido compensada pela maior seleção de atributos para esse período, igualando a capacidade de discriminação das fitofisionomias em relação ao período seco.

Figura 5.18 Gráfico *boxplot* das diferenças dos índices Kappa entre as classificações dos períodos seco e chuvoso.



Fonte: Produção da autora.

Já para o atributo índices de vegetação pode-se afirmar que a igualdade estatística se justifica pela semelhança entre os índices selecionados para os períodos chuvoso e seco. Para ambos os períodos, dos 14 índices selecionados, 10 índices foram comuns a ambos os períodos.

Como o cálculo das diferenças dos índices Kappa foi feito considerando a ordem "período seco menos período chuvoso" nota-se ainda que a maioria das FDPs apresentou sinal negativo, comprovando valores mais altos de índice Kappa para o período chuvoso que para o período seco. As classificações que apresentaram valores positivos ocorreram em relação ao algoritmo SAM, para os atributos derivada de 1ª ordem, parâmetros de bandas de absorção e todos os atributos em conjunto, representando a ocorrência de melhores classificações no período seco que no período chuvoso. Esse resultado foi coerente com o apresentado pela Figura 5.13.

O processo de simulação estocástica permitiu ainda calcular o percentual de acerto para cada uma das fitofisionomias em relação às cinco melhores classificações dos períodos chuvoso e seco. Nota-se que a discriminação das fitofisionomias campestres (CL, CLM, CS e CS/A/CE) no período chuvoso (Figura 5.19) alcançou os melhores resultados quando consideradas as classificações de todos os atributos em conjunto, associados aos classificadores RF (20) e SVM (18). Tais classificações obtiveram as maiores frequências de ocorrência para a discriminação das fitofisionomias campestres.

Os resultados estão de acordo com aqueles apresentados pela matriz de confusão, em relação à exatidão do usuário. Pelo *ranking* das melhores exatidões no período chuvoso, os mais altos valores corresponderam à 80,78% e 79,00% para ambas as classificações, respectivamente (Tabela 5.14).

Período chuvoso - Janeiro						
Fitofisionomias campestres				Fitofisionomias arbóreas		
Ranking	Atributo	Classificador	Exatidão do usuário - média (%)	Atributo	Classificador	Exatidão do usuário - média (%)
1°	Todos os atributos	SVM	80,782	Todos os atributos	SVM	91,247
2°	Todos os atributos	RF	79,002	Índices de vegetação	SVM	90,415
3°	Índices de vegetação	SVM	73,775	Todos os atributos	RF	90,29
4°	Derivada de 1º ordem	RF	73,165	Reflectância	RF	90,002
5°	Índices de vegetação	RF	73,147	Índices de vegetação	RF	89,662
6°	Reflectância	SVM	72,487	Reflectância	SVM	89,15
7°	Reflectância	RF	70,922	Derivada de 1º ordem	RF	86,172
8°	Derivada de 1º ordem	SVM	70,32	Derivada de 1º ordem	SVM	79,675
9°	Reflectância	J48	69,85	Todos os atributos	J48	79,402
10°	Índices de vegetação	J48	68,29	Parâmetros de bandas de absorção	SVM	78,59
11°	Todos os atributos	J48	66,052	Índices de vegetação	J48	78,35
12°	Derivada de 1º ordem	J48	63,06	Reflectância	J48	76,17
13°	Parâmetros de bandas de absorção	o RF	57,79	Reflectância	SAM	68,83
14°	Reflectância	SAM	50,77	Derivada de 1º ordem	J48	68,81
15°	Índices de vegetação	SAM	49,715	Parâmetros de bandas de absorção	RF	66,882
16°	Parâmetros de bandas de absorção	J48	46,792	Parâmetros de bandas de absorção	J48	66,012
17°	Parâmetros de bandas de absorção	o SVM	45,523	Índices de vegetação	SAM	60,805
18°	Todos os atributos	SAM	29,29	Todos os atributos	SAM	39,54
19°	Parâmetros de bandas de absorção	SAM	22,575	Derivada de 1º ordem	SAM	36,287
20°	Derivada de 1º ordem	SAM	22,052	Parâmetros de bandas de absorção	SAM	15,457

Tabela 5.14 Exatidão do usuário média, no período chuvoso, para as fitofisionomias campestres e arbóreas.

Em relação à discriminação das fitofisionomias arbóreas (CC, CCT, CSS e MG) no período chuvoso, as melhores classificações estiveram relacionadas ao atributo índices de vegetação, juntamente ao classificador SVM (14), e a todos os atributos em conjunto, associados aos algoritmos de classificação SVM e RF. De igual forma, para essas classificações, houve concordância em relação às maiores exatidões do usuário dadas pela matriz de confusão. Em relação à classificação "índices de vegetação – SVM", a exatidão do usuário foi de 91,41%, enquanto que as exatidões associadas a todos os atributos em conjunto, para os classificadores SVM (18) e RF (20), foram 91,24% e 90,29%, respectivamente.



Figura 5.19 Percentual de acerto das fitofisionomias em relação às cinco melhores classificações no período chuvoso (Janeiro).

Fonte: Produção da autora.

Já em relação ao período seco (Figura 5.20), as classificações mais robustas utilizadas para a discriminação das fitofisionomias campestres foram aquelas associadas a todos os atributos em conjunto, em relação aos classificadores SVM (18) e RF (20). Esses resultados também concordaram com as maiores exatidões do usuário, sendo essas 76,35% e 75,16% para ambas as classificações, respectivamente (Tabela 5.15).

As classificações que obtiveram o melhor desempenho em relação à discriminação das fitofisionomias arbóreas estiveram associadas a todos os atributos em conjunto, em relação aos algoritmos RF (20) e SVM (18); ao atributo índices de vegetação juntamente aos classificadores RF (16) e SVM (14); e ainda ao atributo reflectância,
associado aos algoritmos RF (4) e SVM (2). As exatidões do usuário para essas classificações estão expressas na Tabela 5.15, com destaque para as classificações de todos os atributos em conjunto, associadas aos algoritmos RF e SVM, que apresentaram exatidões de 85,68% e 85,47%, respectivamente.

			Período seco -	Junho		
	Fitofisionomias ca	ampestres		Fitofisionon	nias arbóreas	
Ranking	Atributo	Classificador	Exatidão do usuário - média (%)	Atributo	Classificador	Exatidão do usuário - média (%)
1°	Todos os atributos	SVM	76,355	Todos os atributos	SVM	85,685
2°	Todos os atributos	RF	75,16	Todos os atributos	RF	85,475
3°	Índices de vegetação	RF	71,185	Índices de vegetação	RF	79,527
4°	Índices de vegetação	SVM	69,975	Reflectância	SVM	78,935
5°	Reflectância	SVM	67,422	Reflectância	RF	78,512
6°	Reflectância	RF	64,745	Índices de vegetação	SVM	77,822
7°	Reflectância	J48	63,38	Todos os atributos	J48	74,425
8°	Derivada de 1º ordem	RF	58,385	Índices de vegetação	J48	73,97
9°	Derivada de 1º ordem	SVM	57,605	Reflectância	J48	72,84
10°	Todos os atributos	J48	57,112	Parâmetros de bandas de absorção	J48	71,91
11°	Índices de vegetação	J48	56,167	Parâmetros de bandas de absorção	SVM	69,37
12°	Derivada de 1º ordem	J48	46,947	Reflectância	SAM	67,31
13°	Parâmetros de bandas de absorção	SVM	46,37	Índices de vegetação	SAM	63,575
14°	Parâmetros de bandas de absorção	J48	43,067	Todos os atributos	SAM	62,465
15°	Todos os atributos	SAM	39,492	Derivada de 1º ordem	RF	59,82
16°	Índices de vegetação	SAM	38,792	Derivada de 1º ordem	SVM	58,027
17°	Reflectância	SAM	37,69	Parâmetros de bandas de absorção	RF	54,95
18°	Derivada de 1º ordem	SAM	37,562	Derivada de 1º ordem	J48	46,517
19°	Parâmetros de bandas de absorção	RF	32,89	Derivada de 1º ordem	SAM	41,197
20°	Parâmetros de bandas de absorção	SAM	17,087	Parâmetros de bandas de absorção	SAM	27,727

Tabela 5.15 Exatidão do usuário média, no período seco, para as fitofisionomias campestres e arbóreas.

Fonte: Produção da autora.

Comparando a média do percentual de acerto de cada fitofisionomia, em relação aos períodos chuvoso e seco, tem-se que as fitofisionomias CC e CL foram igualmente melhor classificadas em ambos os períodos. Já as fitofisionomias CCT, CLM, CS, CS/A/CE e CSS obtiveram maior média de percentual de acerto no período chuvoso, enquanto que a fitofisionomia MG foi melhor classificada no período seco.



Figura 5.20 Percentual de acerto das fitofisionomias em relação às cinco melhores classificações do período seco (Junho).

Fonte: Produção da autora.

A partir da concordância entre os resultados obtidos neste estudo pode-se afirmar que as técnicas de simulação estocástica foram essenciais para a complementação e confirmação dos resultados estatísticos associados aos processos de classificação de imagens do sensor Hyperion.

#### 6 CONCLUSÃO

Diante das características sazonais do ambiente Cerrado e em específico da área de estudo em questão, este estudo visou aprimorar conhecimentos a respeito da utilização de atributos hiperespectrais do sensor Hyperion/EO-1 para a diferenciação de fitofisionomias do Parque Nacional de Brasília (PNB) usando diferentes classificadores nos períodos chuvoso e seco. Essa investigação foi um estudo preparatório para as futuras missões hiperespectrais, como a do EnMAP, com lançamento previsto para 2019, que irá adquirir imagens com largura de faixa de imageamento e relação sinal/ruído no SWIR superiores às especificações do Hyperion.

Como conclusão geral, os resultados mostraram-se robustos quanto à discriminação de fitofisionomias do Cerrado a partir da seleção de atributos hiperespectrais, que foram utilizados como dados de entrada para as classificações. Conclui-se, portanto, que a hipótese deste estudo foi aceita, uma vez que o uso combinado de diferentes atributos do sensor Hyperion/EO-1 contribuiu para o melhor desempenho dos algoritmos de classificação supervisionados. A maior confusão espectral entre as fitofisionomias no período chuvoso foi compensada pela seleção de um maior número de atributos, quando comparado com o período seco, com as técnicas RF e SVM apresentando os melhores resultados de classificação.

Em relação à caracterização da resposta sazonal das fitofisionomias do PNB, por meio dos atributos hiperespectrais do sensor Hyperion/EO-1, pode-se dizer que para esse estudo a geometria de aquisição dos dados exerceu influência sobre o brilho das cenas nos períodos chuvoso e seco, em decorrência dos maiores valores de AZS e da diminuição do ângulo azimutal solar (AAS) de janeiro para junho, em combinação com o ângulo de apontamento elevado do sensor e da deriva do satélite EO-1 em sua etapa final de funcionamento.

Os espectros de reflectância apresentaram diferenças marcantes associadas à sazonalidade dos períodos chuvoso e seco. Em relação à região do visível, observou-se a redução do pico de reflectância no verde do período chuvoso para o seco. Além disso, notou-se que as bandas de absorção mais profundas de clorofila e água

estiveram associadas às fitofisionomias arbóreas em decorrência do adensamento da vegetação e, consequentemente, à manutenção da atividade fotossintética. Para o atributo derivada de 1<sup>a</sup> ordem, foi observada maior taxa de variação para as fitofisionomias arbóreas, de forma mais acentuada para o período chuvoso. Os índices de vegetação foram escolhidos para representar os aspectos estruturais, bioquímicos e fisiológicos da vegetação, sendo que as maiores variações sazonais foram observadas para as fitofisionomias campestres. Em relação aos parâmetros de bandas de absorção observou-se correlação positiva entre a profundidade e área das bandas de absorção de clorofila e água, centradas em 680 nm e 1200 nm, respectivamente.

Com respeito a seleção dos atributos hiperespectrais mais importantes para a discriminação das fitofisionomias nos períodos chuvoso e seco, e ao desempenho dos diferentes classificadores testados neste estudo, os resultados mostraram que a maior quantidade de atributos selecionados para o período chuvoso pode ter compensado as confusões espectrais inerentes à estrutura da vegetação durante esse período. Concluise ainda que a menor frequência de chuvas para o ano de 2015 exerceu influência para as melhores classificações no período chuvoso, principalmente em relação aos algoritmos de classificação RF e SVM e à fitofisionomia Campo Cerrado com trembleia (espécie invasora). As maiores exatidões totais foram atribuídas às classificações de todos os atributos em conjunto, enquanto os atributos parâmetros de bandas de absorção e derivada de 1<sup>a</sup> ordem apresentaram as menores exatidões.

A quantificação das incertezas por meio da entropia de Shannon mostrou que os maiores valores de entropia ocorreram para os atributos derivada de 1ª ordem e parâmetros de bandas de absorção, no que diz respeito às regras de decisão dos algoritmos de classificação. Quanto à classificação das fitofisionomias, os mapas de moda mostraram que as maiores incertezas ocorreram para a vegetação campestre, concordando com o que foi apresentado nos mapas de entropia.

Por meio das médias de índice Kappa, obtidas a partir do processo de simulação estocástica, conclui-se que as classificações do período chuvoso obtiveram desempenho ligeiramente superior em relação às classificações do período seco, mas

que na maioria dos casos elas não foram estatisticamente diferentes. Os menores valores de média do índice Kappa ocorreram para o atributo parâmetros de bandas de absorção, associado ao classificador SAM, em ambos os períodos, enquanto o algoritmo de classificação RF alcançou os melhores resultados.

Considerando um intervalo de credibilidade de 99%, pode-se afirmar que as classificações dos períodos chuvoso e seco somente se diferenciaram para cada conjunto de atributo usando o classificador RF. Portanto, as melhores diferenciações entre as classificações de ambos os períodos se deu para o algoritmo de classificação RF, o qual proporcionou maior robustez quanto à distribuição dos dados.

O percentual de acerto calculado para cada uma das fitofisionomias por meio da simulação estocástica permitiu concluir ainda que as melhores classificações para discriminação de fitofisionomias campestres ocorreram para os algoritmos SVM e RF, associados a todos os atributos em conjunto, nos períodos chuvoso e seco. Já em relação às fitofisionomias arbóreas, as classificações que se destacaram foram aquelas referentes aos atributos índice de vegetação (SVM) e todos os atributos em conjunto (SVM e RF) no período chuvoso. Quanto ao período seco, tiveram destaque as classificações de todos os atributos em conjunto, dos atributos índices de vegetação e do atributo reflectâcia, todos em relação aos algoritmos SVM e RF. Tais resultados estiveram de acordo com as exatidões do usuário obtidas pelas matrizes de confusão de cada classificação.

A partir da concordância entre os resultados obtidos neste estudo, conclui-se que a simulação estocástica foi importante para a complementação e a confirmação dos resultados estatísticos associados aos processos de classificação de imagens orbitais.

Como recomendações para estudos futuros usando dados hiperespectrais no PNB, sugere-se aplicar a presente metodologia com dados do EnMAP, que será lançado em 2019. Visto que a relação sinal/ruído do EnMAP será bastante superior ao do Hyperion, é possível que vários atributos analisados neste trabalho que não apresentaram bons resultados de classificação por sua sensibilidade ao ruído

instrumental e de pré-processamento dos dados, como, por exemplo, os parâmetros de bandas de absorção no SWIR, possam ter sua relevância melhorada.

### **REFERÊNCIAS BIBLIOGRÁFICAS**

ASNER, G. P. Biophysical and biochemical sources of variability in canopy reflectance. **Remote Sensing of Environment**, v. 64, n. 3, p. 234-253, 1998.

BANNARI, A.; STAENZ, K.; CHAMPAGNE, C.; KHURSHID, K. Spatial variability mapping of crop residue using Hyperion (EO-1) hyperspectral data. **Remote Sensing**, v. 7, n. 6, p. 8107-8127, 2015.

BARBOSA, C. C. F. Sensoriamento remoto da dinâmica da circulação da água do sistema planície de Curuai/Rio Amazonas. 2005. 286 p.

IBI: <6qtX3pFwXQZGivnJSY/KfjFc>. (INPE-14614-TDI/1193). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2005. Disponível em: <<u>http://urlib.net/6qtX3pFwXQZGivnJSY/KfjFc</u>>

BARTON, C. V. M.; NORTH, P. R. J. Remote sensing of canopy light use efficiency using the photochemical reflectance index model and sensitivity analysis. **Remote Sensing of Environment**, v. 78, n. 3, p. 264-273, 2001.

BLACKBURN, G. A. Quantifying Chlorophylls and Caroteniods at Leaf and Canopy Scales. **Remote Sensing of Environment**, v. 66, n. 3, p. 273-285, 1998.

BLOCH, S. L.; SØRENSEN, M. S. The role of connectivity and stochastic osteocyte behavior in the distribution of perilabyrinthine bone degeneration. A Monte Carlo based simulation study. **Hearing Research**, v. 335, n. 10, p. 1-8, 2016.

BREIMAN, L. Random Forests. Machine Learning, v. 45, n. 1, p. 5-32, 2001.

BREUNIG, F. M.; CAMARGO, F. F.; ADAMI, M.; et al. Aplicação da técnica de remoção do contínuo para a discriminação espectral de diferentes dosagens de Nitrogênio aplicadas ao trigo (Triticum aestivum, L. - IAC-370). In: SIMPÓSIO
BRASILEIRO DE SENSORIAMENTO REMOTO, 13. (SBSR)., 2007, Florianópolis.
Anais... São José dos Campos: INPE, 2007. p. 91-98. CD-ROM; On-line. ISBN 978-85-17-00031-7. (INPE-16277-PRE/10857). Disponível
em: <a href="http://urlib.net/dpi.inpe.br/sbsr@80/2006/10.31.11.32">http://urlib.net/dpi.inpe.br/sbsr@80/2006/10.31.11.32</a>

BREUNIG, F. M.; GALVAO, L. S.; FORMAGGIO, A. R.; EPIPHANIO, J. C. N. Classification of soybean varieties using different techniques: case study with Hyperion and sensor spectral resolution simulations. **Journal of Applied Remote Sensing**, v. 5, n. 1, p. 53533-1-53533-15, 2011.

BUSTAMANTE, M. M. C.; OLIVEIRA, E. L. Impacto das atividades agrícolas, florestais e pecuárias nos recursos naturais. In: FALEIRO, F. G.; FARIAS NETO, A. L. (Eds.). Savanas: desafios e estratégias para o equilíbrio entre sociedade, agronegócio e recursos naturais. Planaltina, DF: Embrapa Cerrados, 2008. p.647-669.

CARVALHO, A. P. F.; BUSTAMANTE, M. M. D. C.; KOZOVITS, A. R.; ASNER, G. P. Variações sazonais nas concentrações de pigmentos e nutrientes em folhas de espécies de cerrado com diferentes estratégias fenológicas. **Revista Brasileira de Botânica**, v. 30, n. 1, p. 19-27, 2007.

CARVALHO, O. A. DE; MENESES, P. R.; ABÍLIO, O.; JR, D. C.; MENESES, P. R. Spectral Correlation Mapper (SCM): An Improvement on the Spectral Angle Mapper (SAM). JPL Publication, v. 9, n. 00-18, p. 1-9, 2000.

CLARK, M. L.; ROBERTS, D. A. Species-level differences in hyperspectral metrics among tropical rainforest trees as determined by a tree-based classifier. **Remote Sensing**, v. 4, n. 6, p. 1820-1855, 2012.

CLARK, M. L.; ROBERTS, D. A.; CLARK, D. B. 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, R. N.; ROUSH, T. L. Reflectance spectroscopy: Quantitative analysis techniques for remote sensing applications. **Journal of Geophysical Research**, v. 89, n. B7, p. 6329-6340, 1984.

COHEN, J. A coefficient of agreement of nominal scales. Educational and Psychological Measurement, v. 20, n. 1, p. 37-46, 1960.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35-46, 1991.

CORTES, C.; VAPNIK, V. Support-vector networks. Machine Learning, v. 20, n. 3, p. 273-297, 1995.

COUTINHO, L. M. O conceito de cerrado. **Revista Brasileira de Botânica**, v.1, n.1, p.17-23, 1978.

CURRAN, P. J. Remote sensing of foliar chemistry. **Remote Sensing of Environment**, v. 30, n. 3, p. 271-278, 1989.

DASH, M.; LIU, H. Feature selection for classification. **Intelligent Data Analysis**, v. 1, n. 3, p. 131-156, 1997.

DAUGHTRY, C. Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. **Remote Sensing of Environment**, v. 74, n. 2, p. 229-239, 2000.

DAUGHTRY, C. S. T. Agroclimatology: Discriminating crop residues from soil by shortwave infrared reflectance. **Agronomy Journal**, v. 93, n. 1, p.125-131, 2001.

DEERING, D. W.; MIDDLETON, E. M.; ECK, T. F. Reflectance anisotropy for a spruce-hemlock forest canopy. **Remote Sensing of Environment**, v. 47, n. 2, p. 242-260, 1994.

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

DOYLE, J. P.; RIEF, H. Photon transport in three-dimensional structures treated by random walk techniques: Monte Carlo benchmark of ocean colour simulations. **Mathematics and Computers in Simulation**, v. 47, n. 2-5, p. 215-241, 1998.

EITEN, G. Vegetação natural do Distrito Federal. Brasília: SEBRAE, 2001.162 p.

FELDE, G. W.; ANDERSON, G. P.; COOLEY, T. W.; et al. Analysis of Hyperion data with the FLAASH atmospheric correction algorithm. In: 2003 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM. IGARSS 2003, 2003, Toulouse. **Proceedings...** IEEE, 2003. v. 1, p. 90–92. doi: 10.1109/IGARSS.2003.1293688. (IEEE Cat. No.03CH37477).

FERREIRA, L. G.; ASNER, G. P.; KNAPP, D. E.; et al. Equivalent water thickness in savanna ecosystems: MODIS estimates based on ground and EO-1 Hyperion data. **International Journal of Remote Sensing**, v. 32, p. 7423-7440, 2011.

FERREIRA, L. G.; YOSHIOKA, H.; HUETE, A.; SANO, E. E. Seasonal landscape and spectral vegetation index dynamics in the Brazilian Cerrado: An analysis within the Large-Scale Biosphere-Atmosphere Experiment in Amazônia (LBA) (b). **Remote Sensing of Environment**, v. 87, n. 4, p. 534-550, 2003.

FERREIRA, M. E. Análise do Modelo Linear de Mistura Espectral na
Discriminação de Fitofisionomias do Parque Nacional de Brasília (Bioma Cerrado) (a). 2003. 96 p. Dissertação (Mestrado em Geologia) - Brasília: Universidade de Brasília (UnB), 2003.

FERREIRA, M. E.; FERREIRA, L. G.; SANO, E. E.; SHIMABUKURO, Y. E. Spectral linear mixture modelling approaches for land cover mapping of tropical savanna areas in Brazil. **International Journal of Remote Sensing**, v. 28, n. 2, p. 413-429, 2007.

FLETCHER, T. **Support Vector Machines Explained.** London: UCL, 2009. p. 1-19. doi: 10.1002/9780470503065.app2. Available at: http://sutikno. blog. undip. ac. id/files/2011/11/SVM-Explained. pdf.

FOLKMAN, M. A.; PEARLMAN, J. S.; LIAO, L. B.; JARECKE, P. J. EO-1/Hyperion hyperspectral imager design, development, characterization, and calibration. In: SPIE HYPERSPECTRAL REMOTE SENSING OF THE LAND AND ATMOSPHERE, 40, 2001, Sendai, Japan. **Proceedings...** 2001, p. 40-51.

FREITAS-SILVA, F. H.; CAMPOS, J. E. G. Geologia do Parque Nacional de Brasília - DF. **Boletim de Geociências do Centro-Oeste**, v. 18, n. p. 32-43, 1995.

FRIEDL, M. A.,; BRODLEY, C. E. Decision tree classification of land cover from remotely sensed data. **Remote Sensing of Environment**, v. 61, n. 3, p. 399-409, 1997.

GALVÃO, L. S.; BREUNIG, F. M.; SANTOS, J. R.; MOURA, Y. M. Anisotropia de índices hiperespectrais em florestas tropicais. 16. (SBSR), 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. p. 8916-8923. DVD, Internet. ISBN 978-85-17-00066-9 (Internet), 978-85-17-00065-2 (DVD). IBI: <3ERPFQRTRW34M/3E7GBS9>. Disponível em: <<u>http://urlib.net/3ERPFQRTRW34M/3E7GBS9</u>>

GALVÃO, L. S.; EPIPHANIO, J. C. N.; BREUNIG., F. M.; FORMAGGIO, A. R. Crop Type Discrimination Using Hyperspectral Data. In: THENKABAIL, P. S.; LYON, J. G.; HUETE, A. (Eds.). **Hyperspectral Remote Sensing of Vegetation**. CRC Press, 2011. cap.17, p. 397-421.

GALVÃO, L. S.; FORMAGGIO, A. R.; TISOT, D. A. Discrimination of sugarcane varieties in Southeastern Brazil with EO-1 Hyperion data. **Remote Sensing of Environment**, v. 94, n. 4, p. 523-534, 2005.

GALVÃO, L. S.; PONZONI, F. J.; LIESENBERG, V.; SANTOS, J. R. DOS. Possibilities of discriminating tropical secondary succession in Amazônia using hyperspectral and multiangular CHRIS/PROBA data (a). **International Journal of Applied Earth Observation and Geoinformation**, v. 11, p. 8-14, 2009. GALVÃO, L. S.; ROBERTS, D. A.; FORMAGGIO, A. R.; NUMATA, I.; BREUNIG, F. M. View angle effects on the discrimination of soybean varieties and on the relationships between vegetation indices and yield using off-nadir Hyperion data (b). **Remote Sensing of Environment**, v. 113, n. 4, p. 846-856, 2009.

GAMON, J. A.; PEÑUELAS, J.; FIELD, C. B. A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. **Remote Sensing of Environment**, v. 41, n. 1, p. 35-44, 1992.

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.

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.

GAO, B.-C.; GOETZ, A. F. H. Column atmospheric water vapor and vegetation liquid water retrievals from Airborne Imaging Spectrometer data. **Journal of Geophysical Research**, v. 95, n. D4, p. 3549-3564, 1990.

GIROUARD, G.; BANNARI, A.; HARTI, A. EL; DESROCHERS, A. Validated spectral angle mapper algorithm for geological mapping: comparative study between QuickBird and Landsat-TM. In: INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING - ISPRS CONGRESS, 20, 2004, Istanbul, Turkey. **Proceedings...** Ottawa: University of Ottawa, 2003. p. 599-604.

GISLASON, P. O.; BENEDIKTSSON, J. A.; SVEINSSON, J. R. Random forests for land cover classification. **Pattern Recognition Letters**, v. 27, p. 294-300, 2006.

GITELSON, A A; MERZLYAK, M. N.; CHIVKUNOVA, O. B. Optical properties and nondestructive estimation of anthocyanin content in plant leaves. **Photochemistry and photobiology**, v. 74, n. 1, p. 38-45, 2001.

GITELSON, A. A; ZUR, Y.; CHIVKUNOVA, O. B.; MERZLYAK, M. N. Assessing carotenoid content in plant leaves with reflectance spectroscopy.(b). **Photochemistry and photobiology**, v. 75, n. 3, p. 272-281, 2002.

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, 2002.

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.

GOEL, N. S. Models of vegetation canopy reflectance and their use in estimation of biophysical parameters from reflectance data. **Remote Sensing Reviews**, v. 4, p. 1-212, 1988.

GÓMEZ, C.; WHITE, J. C.; WULDER, M. A. Optical remotely sensed time series data for land cover classification: a review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 116, p. 55-72, 2016.

GUANTER, L.; KAUFMANN, H.; SEGL, K.The EnMAP spaceborne imaging spectroscopy mission for earth observation. **Remote Sensing**. v. 7, p. 8830-8857, 2015.

HALL, M. A. **Correlation-based Feature Selection for Machine Learning**. 178 p. Thesis (Doctor of Philosophy) - Nova Zelândia: University of Waikato, 1999.

HALL, M.; FRANK, E.; HOLMES, G.; et al. The WEKA data mining software: an update. **SIGKDD Exploratios**, v. 11, n. 1, p. 10-18, 2009.

HALTON, J. H. A Retrospective and Prospective Survey of the Monte Carlo Method. **SIAM Review**, v. 12, n. 1, p. 1-63, 1970.

HAN, J.; KAMBER, M. Data Mining: Concepts and Techniques. 26 p. 2006.

HOCHBERG, E. J.; ROBERTS, D. A.; DENNISON, P. E.; HULLEY, G. C. Special issue on the Hyperspectral Infrared Imager (HyspIRI): Emerging science in terrestrial and aquatic ecology, radiation balance and hazards. **Remote Sensing of Environment**, v. 167, n. 15, p. 1-5, 2015.

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.

HUETE, A.; DIDAN, K.; MIURA, T.; et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195-213, 2002.

HUGHES, G. On the mean accuracy of statistical pattern recognizers. **IEEE Transactions on Information Theory**, v. 14, n. 1, p. 55-63, 1968.

HUNT JR, E. R.; ROCK, B. N. Detection of changes in leaf water content using Nearand Middle-Infrared reflectances. **Remote Sensing of Environment**, v. 30, n. 1, p. 43-54, 1989.

IMMITZER, M.; ATZBERGER, C.; KOUKAL, T. Tree species classification with Random forest using very high spatial resolution 8-band worldView-2 satellite data. **Remote Sensing**, v. 4, n. 9, p. 2661-2693, 2012.

JACON, A. D.; GALVÃO, L. S.; SANTOS, J. R.; SANO, E. E. Seasonal characterization and discrimination of savannah physiognomies in Brazil using hyperspectral metrics from Hyperion/EO-1. Aceito pela revista International Journal of Remote Sensing, 2017.

JIANG, Z.; HUETE, A. R. Linearization of NDVI Based on its Relationship with Vegetation Fraction. **Photogrammetric Engineering and Remote Sensing**, v. 76, n. 8, p. 965–975, 2010.

KOKALY, R. F. **PRISM: Processing routines in IDL for spectroscopic measurements (installation manual and user's guide, version 1.0)**. U.S. Geological Survey open-file report, 2011. 431 p.

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, n. SUPPL. 1, p. S78-S91, 2009.

KOKALY, R. F.; CLARK, R. N. Spectroscopic determination of leaf biochemistry using band-depth analysis of absorption features and stepwise multiple linear regression. **Remote Sensing of Environment**, v. 67, n. 3, p. 267-287, 1999.

KOKALY, R. F.; SKIDMORE, A. K. Plant phenolics and absorption features in vegetation reflectance spectra near 1.66 µm. **International Journal of Applied Earth Observation**, v. 43, p. 55-83, 2015.

KRUSE, F. A.; LEFKOFF, A. B.; BOARDMAN, J. W.; et al. The spectral image processing system (SIPS) interactive visualization and analysis of imaging spectrometer data (b). **Remote Sensing of Environment**, v. 44, n. 2-3, p. 145-163, 1993.

KRUSE, F. A.; LEFKOFF, A. B.; DIETZ, J. B. Expert system-based mineral mapping in northern death valley, California/Nevada, using the Airborne Visible/Infrared

Imaging Spectrometer (AVIRIS) (a). **Remote Sensing of Environment**, v. 44, n. 2-3, p. 309-336, 1993.

LANDIS, D. R.; MIDDLETON, E. M.; UNGAR, S. G. EO-1: 15 Years After the Start of Its "One-Year Mission." In: PLATNICK, S (Ed.). **The Earth Observer**. USA: NASA, 2016. v. 28, p. 4-14.

LIESENBERG, V.; GALVÃO, L. S.; PONZONI, F. J. Variations in reflectance with seasonality and viewing geometry: Implications for classification of Brazilian savanna physiognomies with MISR/Terra data. **Remote Sensing of Environment**, v. 107, n. 1-2, p. 276-286, 2007.

LINDEN, S. VAN DER; RABE, A.; HELD, M.; et al. The EnMAP-box-A toolbox and application programming interface for EnMAP data processing. **Remote Sensing**, v. 7, n. 9, p. 11249-11266, 2015.

MARTINS, C. R.; HAY, J. D. V.; VALLS, J. F. M.; LEITE, L. L.; HENRIQUES, R. P. B. Levantamento das gramíneas exóticas do Parque Nacional de Brasília, Distrito Federal, Brasil. Natureza & Conservação, v. 5, n. 2, p. 23-30, 2007.

MEER, F. VAN DER. Analysis of spectral absorption features in hyperspectral imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 5, n. 1, p. 55-68, 2004.

MERTON, R.; HUNTINGTON, J. Early simulation of the ARIES-1 satellite sensor for multi-temporal vegetation research derived from AVIRIS. In: JPL AIRBORNE EARTH SCIENCE WORKSHOP. Pasadena. **Proceedings...** Pasadena: JPL, 1999. p.299-307.

MERZLYAK, M. N.; GITELSON, A. A; CHIVKUNOVA, O. B.; RAKITIN, V. Y. U. Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. **Physiologia Plantarum**, v. 106, n. 1, p. 135-141, 1999.

MIURA, T.; HUETE, A. R.; FERREIRA, L. .; SANO, E. Discrimination and biophysical characterization of Cerrado physiognomies with EO-1 hyperspectral Hyperion. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11, (SBSR)., 2003, Belo Horizonte. **Anais...** São José dos Campos: INPE, 2003. p. 1077-1082. CD-ROM, Online. ISBN 85-17-00017-X. Disponível em: <<u>http://urlib.net/ltid.inpe.br/sbsr/2002/11.17.01.11</u>>

MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing:

A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 3, p. 247-259, 2011.

MYERS, N.; MYERS, N.; MITTERMEIER, R. A; et al. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. 6772, p. 853-858, 2000.

ONIK, A. R.; HAQ, N. F.; ALAM, L. An Analytical Comparison on Filter Feature Extraction Method in Data Mining using J48 Classifier. **International Journal of Computer Applications**, v. 124, n. 13, p. 2-8, 2015.

PAL, M.; FOODY, G. M. Feature selection for classification of hyperspectral data by SVM. **IEEE Transactions on Geoscience and Remote Sensing**, v. 48, n. 5, p. 2297-2307, 2010.

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, n. 2, p. 342-354, 2010.

PEARLMAN, J. S.; BARRY, P. S.; SEGAL, C. C.; et al. Hyperion, a space-based imaging spectrometer. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 6, p. 1160-1173, 2003.

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.

PEÑUELAS, J.; PINOL, J.; OGAYA, R.; FILELLA, I. Estimation of plant water concentration by the reflectance Water Index WI (R900/R970). **International Journal of Remote Sensing**, v. 18, n. 13, p. 2869-2875, 1997.

PINHEIRO, G. G. C. Análise dos dados digitais de imagem de radar (satélite JERS-1, banda L) para estudos de vegetação, solos e geologia na região do Cerrado. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 9, 1999, Santos. **Anais...** Brasília: Universidade de Brasília (UnB), 1999. p. 185-188. Disponível em: <marte.sid.inpe.br/col/sid.inpe.br/deise/1999/02.09.14.47/doc/4\_84p.pdf>.

PLATT, J. C. Fast training of support vector machines using sequential minimal optimization. In: SCHÖLKOPF, B.; BURGES, C. J. C.; SMOLA, A. J. (Ed.). Advances in kernel methods. Cambridge, 1999, p. 185-208.

PONZONI, F. J.; GALVÃO, L. S.; LIESENBERG, V.; SANTOS, J. R. Impact of

multi-angular CHRIS/PROBA data on their empirical relationships with tropical forest biomass. **International Journal of Remote Sensing**, v. 31, n. 19, p. 5257-5273, 2010.

PRODAN, A.; PRODAN, R. Stochastic simulation and modelling. Romania: Iuliu Hațieganu University. 2001, p. 461-466.

QI, J.; INOUE, Y.; WIANGWANG, N. Hyperspectral Remote Sensing in Global Change Studies. In: THENKABAIL, A.; LYON, P. S.; HUETE, J. C. (Eds.). **Hyperspectral Remote Sensing of Vegetation**. CRC Press, 2011. cap.3, p. 69-90.

QUINLAN, J. R. Improved use of continuous attributes in C4.5. Journal of Artificial Intelligence Research, v. 4, p. 77-90, 1996.

QUINLAN, R. **C4.5: Programs for Machine Learning.** KAUFMANN, M. (Ed.). San Francisco California, 1992.

RAMOS, P. C. M. Vegetation communities and soils in National Park of Brasília. 1995. 216 p. Tese (Doutorado) - Edinburgh:University of Edinburgh, 1995.

RIBEIRO, J. F.; WALTER, B. M. T. Fitofisionomias do bioma cerrado. In: SANO, S.
M. (ed.). Cerrado: ambiente e flora. Brasília: Empresa Brasileira de Pesquisa
Agropecuária, Centro de Pesquisa Agropecuária dos Cerrados, Ministério da
Agricultura e do Abastecimento, 1998. p.89–166.

RIBEIRO, J. F.; WALTER, B. M. T. As principais fitofisionomias do Bioma Cerrado. In: SANO, M. S.; ALMEIRA, S. P.; RIBEIRO, J. F. (eds.). Cerrado: ecologia e flora. Brasília: Embrapa Informação Tecnológica, 2008. p.151–212.

ROBERTS, D. A; ROTH, K. L.; PERROY, R. L. Hyperspectral Vegetation Indices. In: THENKABAIL, A.; LYON, P. S.; HUETE, J. C. (Eds.). **Hyperspectral Remote Sensing of Vegetation**. CRC Press, 2011. cap.14, p. 309-327.

ROBERTS, D. A.; USTIN, S. L.; OGUNJEMIYO, S. Spectral and Structural Measures of Northwest Forest Vegetation at Leaf to Landscape Scales. **Ecosystems**, v. 7, n. 5, p. 545-562, 2004.

ROUSE, J. F.; WALTER, B. M. T. Monitoring Vegetation Systems in the Great Plains with ERTS. In: ERTS-1 SYMPOSIUM, 3, 1974, Greenbelt. **Proceedings...** Greenbelt: NASA, 1973. p. 309-317. (NASA SP-351).

SANCHES, I. D. A.; SOUZA FILHO C. R.; KOKALY R. F. Spectroscopic remote sensing of plant stress at leaf and canopy levels using the chlorophyll 680nm

absorption feature with continuum removal. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 97, p. 111–122, 2015.

SANO, E. E.; FERREIRA, L. G.; HUETE, A. R. Synthetic aperture radar (L band) and optical vegetation indices for discriminating the Brazilian savanna physiognomies: A comparative analysis. **Earth Interactions**, v. 9, n. 15, p. 1-15, 2005.

SANO, E. E.; PINHEIRO, G. G. C.; MENESES, P. R. Assessing JERS-1 synthetic aperture radar data for vegetation mapping in the Brazilian savanna. **Journal of the Remote Sensing Society of Japan**, v. 21, n. 2, p. 158-167, 2001.

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. 2-3, p. 355-364, 2002.

SHANNON, C. E. A mathematical theory of communication. **The Bell System Technical Journal**, v. 27, n. July 1928, p. 379-423, 1948.

SHRIVAS, A. K.; DEWANGAN, A. K. An Ensemble Model for Classification of Attacks with Feature Selection based on KDD99 and NSL- KDD Data Set. **International Journal of Computer Applications**, v. 99, n. 15, p. 8-13, 2014.

SOUZA, A. A.; GALVÃO, L. S.; SANTOS, J. R. Relationships between Hyperionderived vegetation indices, biophysical parameters, and elevation data in a Brazilian savannah environment. **Remote Sensing Letters**, v. 1, n. 1, p. 55-64, 2010.

SUÁREZ, L.; ZARCO-TEJADA, P. J.; SEPULCRE-CANTÓ, G.; et al. Assessing canopy PRI for water stress detection with diurnal airborne imagery. **Remote Sensing of Environment**, v. 112, n. 2, p. 560-575, 2008.

THENKABAIL, P. S.; ENCLONA, E. A.; ASHTON, M. S.; MEER, B. VAN DER. Accuracy assessments of hyperspectral waveband performance for vegetation analysis applications. **Remote Sensing of Environment**, v. 91, n. 3-4, p. 354-376, 2004.

THENKABAIL, P. S.; LYON, J. G.; HUETE, A. Advances in Hyperspectral Remote Sensing of Vegetation and Agricultural Croplands. In: THENKABAIL, A.; LYON, P. S.; HUETE, J. C. (Eds.). **Hyperspectral Remote Sensing of Vegetation**. CRC Press, 2011. cap.1, p. 3-35.

TSAI, F.; PHILPOT, W. Derivative analysis of hyperspectral data. **Remote Sensing of Environment**, v. 66, n. 1, p. 41–51, 1998.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, 1979.

USTIN, S. L.; GITELSON, A. A.; JACQUEMOUD, S. Retrieval of foliar information about plant pigment systems from high resolution spectroscopy. **Remote Sensing of Environment**, v. 113, n. 1, p. S67-S77, 2009.

ÜSTÜN, B.; MELSSEN, W. J.; BUYDENS, L. M. C. Facilitating the application of Support Vector Regression by using a universal Pearson VII function based kernel. **Chemometrics and Intelligent Laboratory Systems**, v. 81, n. 1, p. 29-40, 2006.

VALERIANO, M. D. M. Cálculo do fator topográfico de iluminação solar para modelagem ecofisiológica a partir do processamento de Modelos Digitais de Elevação (MDE). In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15. (SBSR)., 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. p. 5933-5940. DVD, Internet. ISBN 978-85-17-00056-0 (Internet), 978-85-17-00057-7 (DVD). IBI: <3ERPFQRTRW/39ULK4H>. Disponível em: <<u>http://urlib.net/3ERPFQRTRW/39ULK4H</u>>.

VAPNIK, V. N. The Nature of Statistical Learning Theory. New York: Springer-Verlag, 1995. v. 8, 314 p. 1995.

VOGELMANN, J. E.; ROCK, B. N.; MOSS, D. M. Red edge spectral measurements from sugar maple leaves. **International Journal of Remote Sensing**, v. 14, n. 8, p. 1563-1575, 1993.

WOOLLEY, J. T. Reflectance and transmittance of light by leaves. **Plant physiology**, v. 47, n. 5, p. 656-662, 1971.

WU, X.; KUMAR, V.; ROSS, Q. J.; et al. Top 10 algorithms in data mining. **Knowledge and Information Systems**, v. 14, n. 1, p. 1-37, 2008.

ZAINI, N.; MEER, F. VAN DER; WERFF, H. VAN DER. Effect of grain size and mineral mixing on carbonate absorption features in the SWIR and TIR wavelength regions. **Remote Sensing**, v. 4, n. 4, p. 987-1003, 2012.

# APÊNDICE A – MATRIZES DE CONFUSÃO EM RELAÇÃO AOS ATRIBUTOS HIPERESPECTRAIS.

Tabela A.1. Matriz de confusão da classificação SAM, nos períodos chuvoso (a) e seco (b), em relação ao atributo reflectância e para o conjunto separado de *pixels* de validação.

Classes			(	Classifica	ção - Janeir	0			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS/A/CE	CS	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	101	6	0	0	1	41	34	0	183	55.19	44.81
ССТ	14	22	1	12	7	0	6	0	62	35.48	64.52
CL	1	5	74	44	6	10	0	0	140	52.86	47.14
CLM	2	9	41	46	19	4	1	0	122	37.70	62.30
CS/A/CE	3	1	1	7	41	3	0	0	56	73.21	26.79
CS	34	4	18	18	7	94	0	0	175	53.71	46.29
CSS	27	1	0	0	0	1	157	1	187	83.96	16.04
MG	0	0	0	0	0	0	10	132	142	92.96	7.04
Não Classificado	0	0	0	0	0	0	0	1	1		
Total (pixels)	182	48	135	127	81	153	208	134	1068		
Exatidão do usuário (%)	55.49	45.83	54.81	36.22	50.61	61.43	75.48	98.50		Exatidão total:	62.45%
Erros de inclusão (%)	44.51	54.17	45.19	63.78	49.39	38.57	24.52	1.5		Índice Kappa:	0.56

Classes				Total	Exatidão do	Erros de					
Classes	CC	ССТ	CL	CLM	CS/A/CE	CS	CSS	MG	(pixels)	produtor (%)	omissão (%)
СС	82	8	3	13	2	59	16	0	183	44.81	55.19
ССТ	13	39	0	2	0	1	5	2	62	62.90	37.1
CL	3	2	83	44	0	8	0	0	140	59.29	40.71
CLM	3	5	56	35	12	10	1	0	122	28.69	71.31
CS/A/CE	9	9	6	10	17	4	0	1	56	30.36	69.64
CS	41	2	14	49	15	54	0	0	175	30.86	69.14
CSS	18	32	0	0	0	0	137	0	187	73.26	26.74
MG	0	3	0	0	0	0	3	136	142	95.77	4.23
Não Classificado	0	0	0	0	0	0	0	1	1		
Total (pixels)	169	100	162	153	46	136	162	140	1068		
Exatidão do usuário (%)	48.52	39.00	51.23	22.87	36.95	39.70	84.56	97.14		Exatidão total:	54.59%
Erros de inclusão (%)	51.48	61	48.77	77.13	63.05	60.3	15.44	2.86		Índice Kappa:	0.47

Tabela A.2. Matriz de confusão da classificação J48, nos períodos chuvoso (a) e seco (b), em relação ao atributo reflectância e para o conjunto separado de *pixels* de validação.

1	`
(	31
L	u)

Classes			(	Classifica	ção - Jar	neiro			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	129	5	1	0	29	1	15	3	183	70.49	29.51
CCT	8	35	10	0	6	2	0	1	62	56.45	43.55
CL	6	0	101	31	2	0	0	0	140	72.14	27.86
CLM	6	4	34	74	1	3	0	0	122	60.66	39.34
CS	51	5	12	3	99	3	2	0	175	56.57	43.43
CS/A/CE	4	2	2	0	4	44	0	0	56	78.57	21.43
CSS	24	0	0	0	12	0	142	9	187	75.94	24.06
MG	1	0	0	0	0	0	2	140	143	97.9	2.1
Total (pixels)	229	51	160	108	153	53	161	153	1068		
Exatidão do usuário (%)	56.33	68.63	63.13	68.52	64.71	83.02	88.20	91.50		Exatidão total:	71.54%
Erros de inclusão (%)	43.67	31.37	36.87	31.48	35.29	16.98	11.80	8.50		Índice Kappa:	0.66

<u> </u>				Classific	ação - Ju	inho			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	112	2	7	5	53	1	2	0	182	61.54	38.46
CCT	11	25	0	1	7	0	7	3	54	46.3	53.7
CL	2	1	97	40	6	3	0	0	149	65.1	34.9
CLM	12	0	13	85	6	1	1	0	118	72.03	27.97
CS	48	0	11	15	96	2	1	0	173	55.49	44.51
CS/A/CE	13	2	0	2	16	17	0	1	51	33.33	66.67
CSS	9	14	0	0	10	0	152	5	190	80	20
MG	2	5	0	0	0	0	1	143	151	94.7	5.3
Total (pixels)	209	49	128	148	194	24	164	152	1068		
Exatidão do usuário (%)	53.59	51.02	75.78	57.43	49.48	70.83	92.68	94.08		Exatidão total:	68.07%
Erros de inclusão (%)	46.41	48.98	24.22	42.57	50.52	29.17	7.32	5.92		Índice Kappa:	0.62

Tabela A.3. Matriz de confusão da classificação SVM, nos períodos chuvoso (a) e seco (b), em relação ao atributo reflectância e para o conjunto separado de *pixels* de validação.

|--|

Classes				Classifica	nção - Ja	neiro			Total	Exatidão do	Erros de
Classes	CC	CCT	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	151	0	0	0	22	0	10	0	183	82.51	17.49
CCT	0	47	2	1	4	7	0	1	62	75.81	24.19
CL	1	2	103	26	8	0	0	0	140	73.57	26.43
CLM	0	3	44	69	6	0	0	0	122	56.56	43.44
CS	30	0	13	4	127	0	1	0	175	72.57	27.43
CS/A/CE	0	0	1	2	8	45	0	0	56	80.36	19.64
CSS	17	0	0	0	0	0	168	2	187	89.84	10.16
MG	1	0	0	0	0	0	2	140	143	97.9	2.1
Total (pixels)	200	52	163	102	175	52	181	143	1068		
Exatidão do usuário (%)	75.5	90.38	63.19	67.65	72.57	86.54	92.82	97.9		Exatidão total:	79.59%
Erros de inclusão (%)	24.5	9.62	36.81	32.35	27.43	13.46	7.18	2.1		Índice Kappa:	0.76

			(	Classifica	ção - Ju	nho			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	145	3	7	4	18	1	4	0	182	79.67	20.33
CCT	9	32	0	0	3	0	9	1	54	59.26	40.74
CL	2	1	111	27	5	3	0	0	149	74.5	25.5
CLM	8	1	38	65	4	1	1	0	118	55.08	44.92
CS	51	0	12	6	101	3	0	0	173	58.38	41.62
CS/A/CE	13	3	0	1	13	19	1	1	51	37.25	62.75
CSS	9	4	0	0	0	0	177	0	190	93.16	6.84
MG	1	6	0	0	0	0	0	144	151	95.36	4.64
Total (pixels)	238	50	168	103	144	27	192	146	1068		
Exatidão do usuário (%)	60.92	64	66.07	63.11	70.14	70.37	92.19	98.63		Exatidão total:	74.34%
Erros de inclusão (%)	39.08	36	33.93	36.89	29.86	29.63	7.81	1.37		Índice Kappa:	0.69

Tabela A.4. Matriz de confusão da classificação RF, nos períodos chuvoso (a) e seco (b), em relação ao atributo reflectância e para o conjunto separado de *pixels* de validação.

|--|

Classes				Classifica	nção - Jai	neiro			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	144	0	0	0	29	0	10	0	183	78.69	21.31
CCT	1	42	4	0	4	9	0	2	62	67.74	32.26
CL	0	1	99	31	9	0	0	0	140	70.71	29.29
CLM	2	0	38	76	3	3	0	0	122	62.3	37.7
CS	26	0	15	3	130	0	1	0	175	74.28	25.72
CS/A/CE	4	0	2	0	4	46	0	0	56	82.14	17.86
CSS	20	0	0	0	0	0	164	3	187	87.7	12.3
MG	0	0	0	0	0	0	2	141	143	98.6	1.4
Total (pixels)	197	43	158	110	179	58	177	146	1068		
Exatidão do usuário (%)	73.1	97.67	62.66	69.09	72.63	79.31	92.66	96.58		Exatidão total:	78.84%
Erros de inclusão (%)	26.9	2.33	37.34	30.91	27.37	20.69	7.34	3.42		Índice Kappa:	0.75

Classes				Classifica	ıção - Ju	inho			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	137	4	7	4	26	1	3	0	182	75.27	24.73
CCT	8	33	0	0	4	0	8	1	54	61.11	38.89
CL	1	1	114	26	3	4	0	0	149	76.51	23.49
CLM	7	0	36	69	5	0	1	0	118	58.47	41.53
CS	46	0	13	6	101	7	0	0	173	58.38	41.62
CS/A/CE	8	3	0	1	17	20	1	1	51	39.22	60.78
CSS	14	6	0	0	1	0	167	2	190	87.89	12.11
MG	1	6	0	0	0	0	0	144	151	95.36	4.64
Total (pixels)	222	53	170	106	157	32	180	148	1068		
Exatidão do usuário (%)	61.71	62.26	67.06	65.09	64.33	62.5	92.78	97.3		Exatidão total:	73.50%
Erros de inclusão (%)	38.29	37.74	32.94	34.91	35.67	37.5	7.22	2.7		Índice Kappa:	0.68

Tabela A.5. Matriz de confusão da classificação SAM, nos períodos chuvoso (a) e seco (b), em relação ao atributo derivada de 1<sup>a</sup> ordem e para o conjunto separado de *pixels* de validação.

|--|

<u></u>			(	Classifica	ção - Janeiro	)			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS/A/CE	CS	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	27	0	36	40	37	2	32	6	180	15.00	85.00
ССТ	5	13	4	17	19	1	3	0	62	20.97	79.03
CL	8	0	80	19	12	6	10	1	136	58.82	41.18
CLM	11	1	32	36	21	13	8	0	122	29.51	70.49
CS/A/CE	2	2	0	13	31	7	1	0	56	55.36	44.64
CS	26	8	25	47	38	14	14	0	172	8.14	91.86
CSS	22	2	15	39	56	14	27	12	187	14.44	85.56
MG	22	5	6	28	25	8	20	28	142	19.72	80.28
Não Classificado	3	0	4	0	0	3	0	1	11		
Total (pixels)	126	31	202	239	239	68	115	48	1068		
Exatidão do usuário (%)	21.42	41.93	39.6	15.06	12.97	20.58	23.47	58.33		Exatidão total:	23.97%
Erros de inclusão (%)	78.58	58.07	60.4	84.94	87.03	79.42	76.53	41.67		Índice Kappa:	0.13

Classes				Classific	ação - Junho				Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS/A/CE	CS	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	76	8	24	27	7	14	8	19	183	41.53	58.47
CCT	6	16	0	8	4	3	14	11	62	25.81	74.19
CL	20	1	69	34	2	4	1	6	137	50.36	49.64
CLM	11	2	33	48	5	15	7	1	122	39.34	60.66
CS/A/CE	3	2	0	9	27	7	4	4	56	48.21	51.79
CS	26	4	7	50	18	45	21	2	173	26.01	73.99
CSS	24	31	1	17	18	14	48	34	187	25.67	74.33
MG	5	10	0	0	4	0	15	108	142	76.06	23.94
Não Classificado	0	0	3	0	0	2	0	1	6		
Total (pixels)	171	74	137	193	85	104	118	186	1068		
Exatidão do usuário (%)	44.44	21.62	50.36	24.87	31.76	43.26	40.67	58.06		Exatidão total:	40.92%
Erros de inclusão (%)	55.56	78.38	49.64	75.13	68.24	56.74	59.33	41.94		Índice Kappa:	0.32

Tabela A.6. Matriz de confusão da classificação J48, nos períodos chuvoso (a) e seco (b), em relação ao atributo derivada de 1ª ordem e para o conjunto separado de *pixels* de validação.

1	>
10	1
10	L J
·-	·/

Classes			(	Classifica	ção - Jai	neiro			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
СС	116	2	1	0	29	0	34	1	183	63.39	36.61
ССТ	4	32	3	9	3	1	8	2	62	51.61	48.39
CL	9	0	102	25	3	1	0	0	140	72.86	27.14
CLM	10	6	39	51	10	3	2	1	122	41.8	58.2
CS	29	5	17	21	96	2	5	0	175	54.85	45.15
CS/A/CE	0	1	0	2	7	46	0	0	56	82.14	17.86
CSS	48	1	0	2	18	0	108	10	187	57.75	42.25
MG	4	1	0	0	5	0	7	126	143	88.11	11.89
Total (pixels)	220	48	162	110	171	53	164	140	1068		
Exatidão do usuário (%)	52.73	66.67	62.96	46.36	56.14	86.79	65.85	90.00		Exatidão total:	63.39%
Erros de inclusão (%)	47.27	33.33	37.04	53.64	43.86	13.21	34.15	10.00		Índice Kappa:	0.57

<u>C</u> ]				Classifica	ıção - Ju	inho			Total	Exatidão do	Erros de
Classes	CC	CCT	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	57	3	32	14	38	2	35	1	182	31.32	68.68
CCT	10	6	1	2	4	0	26	5	54	11.11	88.89
CL	10	1	87	26	15	0	9	1	149	58.39	41.61
CLM	17	0	39	40	10	0	10	2	118	33.9	66.1
CS	30	6	24	28	71	7	6	1	173	41.04	58.96
CS/A/CE	10	0	0	1	8	24	7	1	51	47.06	52.94
CSS	25	12	3	3	20	5	109	13	190	57.37	42.63
MG	2	0	0	0	0	0	33	116	151	76.82	23.18
Total (pixels)	161	28	186	114	166	38	235	140	1068		
Exatidão do usuário (%)	35.4	21.43	46.77	35.09	42.77	63.16	46.38	82.86		Exatidão total:	47.75%
Erros de inclusão (%)	64.6	78.57	53.23	64.91	57.23	36.84	53.62	17.14		Índice Kappa:	0.38

Tabela A.7. Matriz de confusão da classificação SVM, nos períodos chuvoso (a) e seco (b), em relação ao atributo derivada de 1<sup>a</sup> ordem e para o conjunto separado de *pixels* de validação.

(a)
-----

Classes			С	lassificaç	ão - Jar	neiro			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	125	0	9	1	7	1	40	0	183	68.31	31.69
CCT	5	35	2	6	13	0	0	1	62	56.45	43.55
CL	8	1	115	13	3	0	0	0	140	82.14	17.86
CLM	8	3	48	47	13	1	2	0	122	38.52	61.48
CS	13	0	17	9	129	1	6	0	175	73.71	26.29
CS/A/CE	1	1	0	0	8	45	1	0	56	80.36	19.64
CSS	30	0	0	0	23	0	132	2	187	70.59	29.41
MG	1	0	0	0	1	0	13	128	143	89.51	10.49
Total (pixels)	191	40	191	76	197	48	194	131	1068		
Exatidão do usuário (%)	65.45	87.5	60.21	61.84	65.48	93.75	68.04	97.71		Exatidão total:	70.79%
Erros de inclusão (%)	34.55	12.5	39.79	38.16	34.52	6.25	31.96	2.29		Índice Kappa:	0.65

Classes			0	lassificaç	ção - Ju	nho			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	102	0	34	2	16	0	28	0	182	56.04	43.96
CCT	8	1	1	1	8	0	32	3	54	1.85	98.15
CL	13	0	113	10	10	2	1	0	149	75.84	24.16
CLM	5	0	63	26	16	0	8	0	118	22.03	77.97
CS	30	0	13	12	107	0	11	0	173	61.84	38.16
CS/A/CE	10	0	0	2	26	7	5	1	51	13.73	86.27
CSS	33	1	5	1	11	0	136	3	190	71.58	28.42
MG	4	1	0	0	0	0	28	118	151	78.15	21.85
Total (pixels)	205	3	229	54	194	9	249	125	1068		
Exatidão do usuário (%)	49.76	33.33	49.34	48.15	55.15	77.78	54.62	94.4		Exatidão total:	57.12%
Erros de inclusão (%)	50.24	66.67	50.66	51.85	44.85	22.22	45.38	5.6		Índice Kappa:	0.49

Tabela A.8. Matriz de confusão da classificação RF, nos períodos chuvoso (a) e seco (b), em relação ao atributo derivada de 1ª ordem e para o conjunto separado de *pixels* de validação.

1	\	
1	<u>م</u>	
۰.	ar	
•	,	

Classes			С	lassificaç	ão - Jar	neiro			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
СС	134	0	3	0	17	1	28	0	183	73.22	26.78
ССТ	2	46	5	2	4	0	1	2	62	74.19	25.81
CL	2	0	118	17	3	0	0	0	140	84.29	15.71
CLM	3	0	46	57	12	1	2	1	122	46.72	53.28
CS	12	1	17	8	135	1	1	0	175	77.14	22.86
CS/A/CE	3	1	0	1	2	47	1	1	56	83.93	16.07
CSS	19	0	0	1	18	0	145	4	187	77.54	22.46
MG	0	0	0	0	2	0	8	133	143	93.01	6.99
Total (pixels)	175	48	189	86	193	50	186	141	1068		
Exatidão do usuário (%)	76.57	95.83	62.43	66.28	69.95	94	77.96	94.33		Exatidão total:	76.31%
Erros de inclusão (%)	23.43	4.17	37.57	33.72	30.05	6	22.04	5.67		Índice Kappa:	0.72

Classes				Classifica	ção - Ju	inho			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
СС	112	1	33	1	11	2	19	3	182	61.54	38.46
ССТ	10	5	0	0	10	0	21	8	54	9.26	90.74
CL	9	1	116	13	4	3	1	2	149	77.85	22.15
CLM	4	1	61	35	8	1	8	0	118	29.66	70.34
CS	29	1	19	13	102	1	8	0	173	58.95	41.05
CS/A/CE	3	1	0	0	21	17	7	2	51	33.33	66.67
CSS	24	2	4	0	16	1	136	7	190	71.58	28.42
MG	2	2	0	0	0	0	24	123	151	81.46	18.54
Total (pixels)	193	14	233	62	172	25	224	145	1068		
Exatidão do usuário (%)	58.03	35.71	49.79	56.45	59.3	68	60.71	84.83		Exatidão total:	60.49%
Erros de inclusão (%)	41.97	64.29	50.21	43.55	40.7	32	39.29	15.17		Índice Kappa:	0.53

Tabela A.9. Matriz de confusão da classificação SAM, nos períodos chuvoso (a) e seco (b), em relação ao atributo índices de vegetação e para o conjunto separado de *pixels* de validação.

|--|

<u></u>			(	Classifica	ção - Janeiro	)			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS/A/CE	CS	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	86	27	1	4	2	32	31	0	183	46.99	53.01
CCT	13	23	10	3	1	5	7	0	62	37.10	62.90
CL	0	3	75	48	2	12	0	0	140	53.57	46.43
CLM	2	7	36	53	22	2	0	0	122	43.44	56.56
CS/A/CE	1	4	4	15	32	0	0	0	56	57.14	42.86
CS	42	21	17	13	4	68	10	0	175	38.86	61.14
CSS	33	4	0	0	0	1	147	2	187	78.61	21.39
MG	0	1	0	0	0	0	11	130	142	91.55	8.45
Não Classificado	0	0	0	0	0	0	0	1	1		
Total (pixels)	177	90	143	136	63	120	206	133	1068		
Exatidão do usuário (%)	48.58	25.55	52.44	38.97	50.79	56.66	71.35	97.74		Exatidão total:	57.49%
Erros de inclusão (%)	51.42	74.45	47.56	61.03	49.21	43.34	28.65	2.26		Índice Kappa:	0.5

Classes				Classific	ação - Junho				Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS/A/CE	CS	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	56	9	1	11	26	61	19	0	183	30.60	69.40
ССТ	6	29	0	1	2	9	15	0	62	46.77	53.23
CL	1	0	94	25	15	2	2	1	140	67.14	32.86
CLM	0	5	69	32	9	5	2	0	122	26.23	73.77
CS/A/CE	2	2	1	2	34	7	7	1	56	60.71	39.29
CS	16	4	12	49	22	69	3	0	175	39.43	60.57
CSS	11	41	0	0	2	1	126	6	187	67.38	32.62
MG	0	1	0	0	0	1	11	129	142	90.85	9.15
Não Classificado	0	0	0	0	0	0	0	1	1		
Total (pixels)	92	91	177	120	110	155	185	138	1068		
Exatidão do usuário (%)	60.87	31.86	53.1	26.66	30.9	44.51	68.1	93.47		Exatidão total:	53.28%
Erros de inclusão (%)	39.13	68.14	46.90	73.34	69.10	55.49	31.90	6.53		Índice Kappa:	0.46

Tabela A.10. Matriz de confusão da classificação J48, nos períodos chuvoso (a) e seco (b), em relação ao atributo índices de vegetação e para o conjunto separado de *pixels* de validação.

1	>
11	<b>۱</b>
16	11
	~/

<i>C</i> ]			(	Classifica	ção - Jar	neiro			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	113	2	3	0	43	0	21	1	183	61.74	38.26
CCT	1	37	9	6	3	2	1	3	62	59.67	40.33
CL	2	0	106	24	8	0	0	0	140	75.71	24.29
CLM	7	1	51	55	7	1	0	0	122	45.08	54.92
CS	17	11	20	5	120	1	1	0	175	68.57	31.43
CS/A/CE	2	2	0	0	5	47	0	0	56	83.92	16.08
CSS	25	2	0	0	2	0	153	5	187	81.81	18.19
MG	1	0	0	0	0	0	4	138	143	96.5	3.5
Total (pixels)	168	55	189	90	188	51	180	147	1068		
Exatidão do usuário (%)	67.26	67.27	56.08	61.11	63.83	92.15	85.00	93.87		Exatidão total:	72.00%
Erros de inclusão (%)	32.74	32.73	43.92	38.89	36.17	7.85	15.00	6.13		Índice Kappa:	0.67

				Classifica	ıção - Ju	nho			Total	Exatidão do	Erros de
Classes	СС	CCT	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	110	1	13	4	37	0	17	0	182	60.44	39.56
ССТ	13	24	0	2	7	0	7	1	54	44.44	55.56
CL	8	0	108	26	4	3	0	0	149	72.48	27.52
CLM	6	2	56	47	4	2	1	0	118	39.83	60.17
CS	33	0	19	19	94	7	1	0	173	54.33	45.67
CS/A/CE	9	2	0	7	6	25	1	1	51	49.02	50.98
CSS	12	10	0	1	4	1	161	1	190	84.74	15.26
MG	2	3	0	2	0	0	4	140	151	92.72	7.28
Total (pixels)	193	42	196	108	156	38	192	143	1068		
Exatidão do usuário (%)	56.99	57.14	55.1	43.52	60.26	65.79	83.85	97.9		Exatidão total:	66.39%
Erros de inclusão (%)	43.01	42.86	44.9	56.48	39.74	34.21	16.15	2.1		Índice Kappa:	0.6

Tabela A.11. Matriz de confusão da classificação SVM, nos períodos chuvoso (a) e seco (b), em relação ao atributo índices de vegetação e para o conjunto separado de *pixels* de validação.

Classes			(	Classifica	ção - Jar	neiro			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	149	1	0	0	25	0	8	0	183	81.42	18.58
CCT	0	39	8	5	9	0	0	1	62	62.9	37.1
CL	3	0	114	18	5	0	0	0	140	81.43	18.57
CLM	2	0	61	52	6	1	0	0	122	42.62	57.38
CS	13	0	14	3	144	0	1	0	175	82.28	17.72
CS/A/CE	0	3	0	0	8	45	0	0	56	80.36	19.64
CSS	20	0	0	0	1	0	165	1	187	88.24	11.76
MG	0	0	0	0	0	0	4	139	143	97.2	2.8
Total (pixels)	187	43	197	78	198	46	178	141	1068		
Exatidão do usuário (%)	79.68	90.7	57.87	66.67	72.73	97.83	92.7	98.58		Exatidão total:	79.31%
Erros de inclusão (%)	20.32	9.3	42.13	33.33	27.27	2.17	7.3	1.42		Índice Kappa:	0.75

<i>C</i> 1				Classifica	ıção - Ju	nho			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	152	0	6	0	12	1	11	0	182	83.52	16.48
ССТ	9	28	0	0	4	0	10	3	54	51.85	48.15
CL	11	1	118	14	1	4	0	0	149	79.19	20.81
CLM	9	4	60	41	2	2	0	0	118	34.75	65.25
CS	41	0	14	7	104	6	1	0	173	60.11	39.89
CS/A/CE	7	3	0	0	4	35	1	1	51	68.63	31.37
CSS	11	2	0	0	1	0	176	0	190	92.63	7.37
MG	0	7	0	0	0	0	0	144	151	95.36	4.64
Total (pixels)	240	45	198	62	128	48	199	148	1068		
Exatidão do usuário (%)	63.33	62.22	59.6	66.13	81.25	72.92	88.44	97.3		Exatidão total:	74.72%
Erros de inclusão (%)	36.67	37.78	40.4	33.87	18.75	27.08	11.56	2.7		Índice Kappa:	0.7

Tabela A.12. Matriz de confusão da classificação RF, nos períodos chuvoso (a) e seco (b), em relação ao atributo índices de vegetação e para o conjunto separado de *pixels* de validação.

1	>	
1	<u>م</u>	
١.	aı	
•		

Classes			С	lassificaç	ão - Jar	neiro			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
СС	154	0	0	0	21	0	8	0	183	84.15	15.85
ССТ	0	42	6	6	5	1	0	2	62	67.74	32.26
CL	4	0	103	26	7	0	0	0	140	73.57	26.43
CLM	1	0	51	62	7	1	0	0	122	50.81	49.19
CS	15	1	12	5	141	0	1	0	175	80.57	19.43
CS/A/CE	1	4	0	0	4	47	0	0	56	83.92	16.08
CSS	21	0	0	2	2	0	160	2	187	85.56	14.44
MG	1	0	0	0	0	0	3	139	143	97.2	2.8
Total (pixels)	197	47	172	101	187	49	172	143	1068		
Exatidão do usuário (%)	78.17	89.36	59.88	61.39	75.4	95.92	93.92	97.2		Exatidão total:	79.40%
Erros de inclusão (%)	21.83	10.64	40.12	38.61	24.6	4.08	6.08	2.8		Índice Kappa:	0.75

<u>()</u>				Classific	ação - Jı	inho			Total	Exatidão do	Erros de
Classes	CC	CCT	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	136	0	6	1	29	0	10	0	182	74.73	25.27
CCT	7	31	0	0	5	0	10	1	54	57.41	42.59
CL	13	1	110	20	1	4	0	0	149	73.83	26.17
CLM	5	3	44	65	0	1	0	0	118	55.08	44.92
CS	29	0	14	8	117	4	1	0	173	67.63	32.37
CS/A/CE	6	2	0	0	4	37	1	1	51	72.55	27.45
CSS	16	4	0	0	5	0	165	0	190	86.84	13.16
MG	1	5	0	1	0	0	0	144	151	95.36	4.64
Total (pixels)	213	46	174	95	161	46	187	146	1068		
Exatidão do usuário (%)	63.85	67.39	63.22	68.42	72.67	80.43	88.24	98.63		Exatidão total:	75.37%
Erros de inclusão (%)	36.15	32.61	36.78	31.58	27.33	19.57	11.76	1.37		Índice Kappa:	0.71

Tabela A.13. Matriz de confusão da classificação SAM, nos períodos chuvoso (a) e seco (b), em relação ao atributo parâmetros de bandas de absorção e para o conjunto separado de *pixels* de validação.

Classes				Classifi	cação - Janei	ro			Total	Exatidão do	Erros de
Classes	CC	CCT	CL	CLM	CS/A/CE	CS	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	5	1	6	2	55	36	7	71	183	2.73	97.27
CCT	2	1	1	16	10	12	2	18	62	1.61	98.39
CL	4	2	7	28	26	34	2	37	140	5.00	95.00
CLM	4	0	9	54	9	22	0	24	122	44.26	55.74
CS/A/CE	1	1	2	4	18	10	4	16	56	32.14	67.86
CS	4	2	8	24	43	40	1	53	175	22.86	77.14
CSS	11	4	1	3	70	11	7	80	187	3.74	96.26
MG	6	1	0	2	56	10	7	60	142	42.25	57.75
Não Classificado	0	0	0	0	0	0	0	1	1		
Total (pixels)	37	12	34	133	287	175	30	360	1068		
Exatidão do usuário (%)	13.51	8.33	20.58	40.6	6.27	22.85	23.33	16.66		Exatidão total:	17.98%
Erros de inclusão (%)	86.49	91.67	79.42	59.40	93.73	77.15	76.67	83.34		Índice Kappa:	0.07

(a)

(b)
-----

Classes				Classifica	ação - Junho				Total	Exatidão do	Erros de
Classes	СС	ССТ	CL	CLM	CS/A/CE	CS	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	18	10	67	49	8	17	12	2	183	9.84	90.16
ССТ	3	15	2	3	7	7	5	20	62	24.19	75.81
CL	4	0	96	28	4	3	4	0	139	69.06	30.94
CLM	18	2	61	17	4	11	7	2	122	13.93	86.07
CS/A/CE	4	15	3	3	5	4	4	18	56	8.93	91.07
CS	24	32	46	25	8	14	19	7	175	8.00	92.00
CSS	13	40	13	19	16	32	19	35	187	10.16	89.84
MG	1	19	3	4	6	3	7	99	142	69.72	30.28
Não Classificado	0	0	1	0	0	0	0	1	2		
Total (pixels)	85	133	292	148	58	91	77	184	1068		
Exatidão do usuário (%)	21.17	11.27	32.87	11.48	8.62	15.38	24.67	53.8		Exatidão total:	26.50%
Erros de inclusão (%)	78.83	88.73	67.13	88.52	91.38	84.62	75.33	46.20		Índice Kappa:	0.16

Tabela A.14. Matriz de confusão da classificação J48, nos períodos chuvoso (a) e seco (b), em relação ao atributo parâmetros de bandas de absorção e para o conjunto separado de *pixels* de validação.

(	a)	
`		

Classes			(	Classifica	ção - Jai	neiro			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	86	15	3	0	55	1	23	0	183	46.99	53.01
ССТ	10	13	10	6	18	3	1	1	62	20.97	79.03
CL	1	0	90	40	8	1	0	0	140	64.29	35.71
CLM	3	0	60	45	9	4	1	0	122	36.89	63.11
CS	35	14	19	12	87	7	1	0	175	49.71	50.29
CS/A/CE	1	3	20	8	4	20	0	0	56	35.71	64.29
CSS	13	9	0	0	6	0	158	1	187	84.49	15.51
MG	0	3	0	0	0	0	2	138	143	96.5	3.5
Total (pixels)	149	57	202	111	187	36	186	140	1068		
Exatidão do usuário (%)	57.72	22.81	44.55	40.54	46.52	55.56	84.95	98.57		Exatidão total:	59.64%
Erros de inclusão (%)	42.28	77.19	55.45	59.46	53.48	44.44	15.05	1.43		Índice Kappa:	0.52

Classes				Classifica	ção - Ju	inho			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
СС	112	0	12	1	51	2	4	0	182	61.54	38.46
CCT	17	0	0	0	1	1	35	0	54	-	-
CL	15	0	113	11	8	1	1	0	149	75.84	24.16
CLM	8	0	85	12	8	0	5	0	118	10.17	89.83
CS	56	0	29	12	72	3	1	0	173	41.61	58.39
CS/A/CE	16	0	0	0	19	7	8	1	51	13.73	86.27
CSS	23	0	0	0	1	1	163	2	190	85.79	14.21
MG	0	0	0	0	0	0	8	143	151	94.7	5.3
Total (pixels)	247	0	239	36	160	15	225	146	1068		
Exatidão do usuário (%)	45.34	-	47.28	33.33	45	46.66	72.44	97.95		Exatidão total:	58.24%
Erros de inclusão (%)	54.66	-	52.72	66.67	55	53.34	27.56	2.05		Índice Kappa:	0.5

Tabela A.15. Matriz de confusão da classificação SVM, nos períodos chuvoso (a) e seco (b), em relação ao atributo parâmetros de bandas de absorção e para o conjunto separado de *pixels* de validação.

Classes			(	Classificaç	ção - Jar	neiro			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	116	0	2	0	49	0	16	0	183	63.39	36.61
ССТ	18	0	12	5	22	0	4	1	62	-	-
CL	1	0	105	20	14	0	0	0	140	75	25
CLM	2	0	75	33	12	0	0	0	122	27.05	72.95
CS	53	0	22	5	94	0	1	0	175	53.71	46.29
CS/A/CE	4	0	37	6	7	0	2	0	56	-	-
CSS	26	0	0	0	1	0	158	2	187	84.49	15.51
MG	1	0	0	0	0	0	4	138	143	96.5	3.5
Total (pixels)	221	0	253	69	199	0	185	141	1068		
Exatidão do usuário (%)	52.49	-	41.5	47.83	47.24	-	85.41	97.87		Exatidão total:	60.30%
Erros de inclusão (%)	47.51	-	58.5	52.17	52.76	-	14.59	2.13		Índice Kappa:	0.53

(a)

Classes			(	Classificaç	ção - Ju	nho			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	99	0	5	0	66	0	12	0	182	54.4	45.6
CCT	12	0	0	0	1	0	41	0	54	-	-
CL	11	0	122	0	16	0	0	0	149	81.88	18.12
CLM	8	0	92	0	13	0	5	0	118	-	-
CS	59	0	27	0	85	0	2	0	173	49.13	50.87
CS/A/CE	26	0	0	0	15	0	9	1	51	-	-
CSS	23	0	0	0	1	0	165	1	190	86.84	13.16
MG	0	0	0	0	0	0	9	142	151	94.04	5.96
Total (pixels)	238	0	246	0	197	0	243	144	1068		
Exatidão do usuário (%)	41.6	-	49.59	-	43.15	-	67.9	98.61		Exatidão total:	57.40%
Erros de inclusão (%)	58.4	-	50.41	-	56.85	-	32.1	1.39		Índice Kappa:	0.49

Tabela A.16. Matriz de confusão da classificação RF, nos períodos chuvoso (a) e seco (b), em relação ao atributo parâmetros de bandas de absorção e para o conjunto separado de *pixels* de validação.

1	\
14	ור
14	11
	~/

Classes			С	lassificaç	ão - Jar	neiro			Total	Exatidão do	Erros de
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
СС	102	9	2	0	54	1	15	0	183	55.74	44.26
CCT	11	12	9	8	19	1	1	1	62	19.35	80.65
CL	1	3	83	40	12	1	0	0	140	59.29	40.71
CLM	3	2	46	60	11	0	0	0	122	49.18	50.82
CS	30	16	13	10	99	4	3	0	175	56.57	43.43
CS/A/CE	3	1	5	10	3	33	1	0	56	58.93	41.07
CSS	24	6	0	0	3	0	152	2	187	81.28	18.72
MG	1	0	0	0	0	0	3	139	143	97.2	2.8
Total (pixels)	175	49	158	128	201	40	175	142	1068		
Exatidão do usuário (%)	58.29	24.49	52.53	46.88	49.25	82.5	86.86	97.89		Exatidão total:	63.67%
Erros de inclusão (%)	41.71	75.51	47.47	53.12	50.75	17.5	13.14	2.11		Índice Kappa:	0.57

<i>C</i> 1				Classifica	Total	Exatidão do	Erros de				
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	80	3	10	14	62	6	7	0	182	43.96	56.04
CCT	15	5	0	0	7	4	21	2	54	9.26	90.74
CL	11	0	92	30	13	1	2	0	149	61.74	38.26
CLM	7	0	70	23	13	1	4	0	118	19.49	80.51
CS	58	1	16	15	61	17	5	0	173	35.26	64.74
CS/A/CE	10	4	0	3	19	9	5	1	51	17.65	82.35
CSS	29	20	0	1	11	1	125	3	190	65.79	34.21
MG	0	1	0	0	0	0	7	143	151	94.7	5.3
Total (pixels)	210	34	188	86	186	39	176	149	1068		
Exatidão do usuário (%)	38.1	14.71	48.94	26.74	32.8	23.08	71.02	95.97		Exatidão total:	50.37%
Erros de inclusão (%)	61.9	85.29	51.06	73.26	67.2	76.92	28.98	4.03		Índice Kappa:	0.41

Tabela A.17. Matriz de confusão da classificação SAM, nos períodos chuvoso (a) e seco (b), em relação a todos os atributos em conjunto e para o conjunto separado de *pixels* de validação.

<u></u>			(	Classifica	Total	Exatidão do	Erros de				
Classes	CC	ССТ	CL	CLM	CS/A/CE	CS	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	33	21	18	4	3	30	65	9	183	18.03	81.97
CCT	14	11	2	22	2	6	3	2	62	17.74	82.26
CL	1	6	41	48	32	10	2	0	140	29.29	70.71
CLM	1	5	26	71	8	7	4	0	122	58.20	41.80
CS/A/CE	0	0	8	7	17	4	19	1	56	30.36	69.64
CS	21	13	29	34	7	27	42	2	175	15.43	84.57
CSS	26	10	6	7	0	19	99	20	187	52.94	47.06
MG	14	14	1	3	0	5	8	97	142	68.31	31.69
Não Classificado	0	0	0	0	0	0	0	1	1		
Total (pixels)	110	80	131	196	69	108	242	132	1068		
Exatidão do usuário (%)	30.00	13.75	31.30	36.22	24.64	25.00	40.91	73.48		Exatidão total:	37.08%
Erros de inclusão (%)	70.00	86.25	68.70	63.78	75.36	75.00	59.09	26.52		Índice Kappa:	0.27

Classes				Classific	Total	Exatidão do	Erros de				
Classes	CC	CCT	CL	CLM	CS/A/CE	CS	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	70	6	4	27	7	48	21	0	183	38.25	61.75
CCT	8	23	0	2	7	7	15	0	62	37.10	62.90
CL	4	1	78	42	7	6	1	0	139	56.12	43.88
CLM	3	4	66	31	7	9	2	0	122	25.41	74.59
CS/A/CE	0	2	0	0	46	3	5	0	56	82.14	17.86
CS	22	3	13	40	20	76	1	0	175	43.43	56.57
CSS	28	28	0	0	25	4	102	0	187	54.55	45.45
MG	0	1	0	0	1	0	10	130	142	91.55	8.45
Não Classificado	0	0	1	0	0	0	0	1	2		
Total (pixels)	135	68	162	142	120	153	157	131	1068		
Exatidão do usuário (%)	51.85	33.82	48.14	21.83	38.33	49.67	64.96	99.23		Exatidão total:	52.06%
Erros de inclusão (%)	48.15	66.18	51.86	78.17	61.67	50.33	35.04	0.77		Índice Kappa:	0.44

Tabela A.18. Matriz de confusão da classificação J48, nos períodos chuvoso (a) e seco (b), em relação a todos os atributos em conjunto e para o conjunto separado de *pixels* de validação.

(a)	

Classes			(	Classifica		Total	Exatidão do	Erros de			
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	137	0	8	0	17	2	19	0	183	74.86	25.14
CCT	0	40	2	3	15	1	0	1	62	64.52	35.48
CL	1	1	96	37	5	0	0	0	140	68.57	31.43
CLM	4	3	40	72	2	1	0	0	122	59.02	40.98
CS	40	11	17	4	99	3	1	0	175	56.57	43.43
CS/A/CE	2	4	0	3	9	38	0	0	56	67.86	32.14
CSS	21	0	0	0	17	0	148	1	187	79.14	20.86
MG	0	1	0	0	0	0	5	137	143	95.8	4.2
Total (pixels)	205	60	163	119	164	45	173	139	1068		
Exatidão do usuário (%)	66.83	66.67	58.9	60.5	60.37	84.44	85.55	98.56		Exatidão total:	71.82%
Erros de inclusão (%)	33.17	33.33	41.1	39.5	39.63	15.56	14.45	1.44		Índice Kappa:	0.67

Classes			С	lassificaç	Total	Exatidão do	Erros de				
Classes	CC	ССТ	CL	CLM	CS	Е	CSS	MG	(pixels)	produtor (%)	omissão (%)
СС	108	2	5	7	53	1	6	0	182	59.34	40.66
CCT	2	32	0	0	6	0	12	2	54	59.26	40.74
CL	0	1	99	40	5	4	0	0	149	66.44	33.56
CLM	7	3	33	67	7	0	1	0	118	56.78	43.22
CS	35	0	12	17	100	8	1	0	173	57.8	42.2
CS/A/CE	17	2	0	2	9	19	0	2	51	37.25	62.75
CSS	24	8	0	0	5	1	152	0	190	80	20
MG	0	8	0	0	0	0	2	141	151	93.38	6.62
Total (pixels)	193	56	149	133	185	33	174	145	1068		
Exatidão do usuário (%)	55.96	57.14	66.44	50.38	54.05	57.58	87.36	97.24		Exatidão total:	67.23%
Erros de inclusão (%)	44.04	42.86	33.56	49.62	45.95	42.42	12.64	2.76		Índice Kappa:	0.61
Tabela A.19. Matriz de confusão da classificação SVM, nos períodos chuvoso (a) e seco (b), em relação a todos os atributos em conjunto e para o conjunto separado de *pixels* de validação.

(a)	

Classes			С		Total	Exatidão do	Erros de				
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
СС	151	0	0	0	18	0	14	0	183	82.51	17.49
CCT	0	54	2	2	3	0	0	1	62	87.1	12.9
CL	3	1	106	29	1	0	0	0	140	75.71	24.29
CLM	0	0	33	82	7	0	0	0	122	67.21	32.79
CS	15	0	9	3	148	0	0	0	175	84.57	15.43
CS/A/CE	2	2	0	0	4	48	0	0	56	85.71	14.29
CSS	16	0	0	0	0	0	170	1	187	90.91	9.09
MG	0	0	0	0	0	0	3	140	143	97.9	2.1
Total (pixels)	187	57	150	116	181	48	187	142	1068		
Exatidão do usuário (%)	80.75	94.74	70.67	70.69	81.77	100	90.91	98.59		Exatidão total:	84.18%
Erros de inclusão (%)	19.25	5.26	29.33	29.31	18.23	0	9.09	1.41		Índice Kappa:	0.81

(b)

Classes				Classifica	Total	Exatidão do	Erros de				
Classes (		CCT	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	149	0	7	2	16	2	6	0	182	81.87	18.13
ССТ	6	36	0	0	6	0	4	2	54	66.67	33.33
CL	2	1	124	16	2	4	0	0	149	83.22	16.78
CLM	9	2	34	73	0	0	0	0	118	61.86	38.14
CS	15	0	13	5	135	4	1	0	173	78.03	21.97
CS/A/CE	3	3	0	1	4	38	1	1	51	74.51	25.49
CSS	10	0	0	0	3	0	176	1	190	92.63	7.37
MG	0	6	0	0	0	0	0	145	151	96.03	3.97
Total (pixels)	194	48	178	97	166	48	188	149	1068		
Exatidão do usuário (%)	76.8	75	69.66	75.26	81.33	79.17	93.62	97.32		Exatidão total:	82.02%
Erros de inclusão (%)	23.2	25	30.34	24.74	18.67	20.83	6.38	2.68		Índice Kappa:	0.78

Tabela A.20. Matriz de confusão da classificação RF, nos períodos chuvoso (a) e seco (b), em relação a todos os atributos em conjunto e para o conjunto separado de *pixels* de validação.

1	\	
14	ונ	
16	11	
· · ·	~/	

Classes			C	lassificaç		Total	Exatidão do	Erros de			
Classes	CC	CCT	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
CC	155	0	0	0	18	0	10	0	183	84.7	15.3
ССТ	0	52	1	2	6	0	0	1	62	83.87	16.13
CL	2	2	102	27	7	0	0	0	140	72.86	27.14
CLM	0	0	35	80	6	1	0	0	122	65.57	34.43
CS	20	1	10	3	141	0	0	0	175	80.57	19.43
CS/A/CE	2	3	0	1	2	48	0	0	56	85.71	14.29
CSS	16	0	0	0	0	0	170	1	187	90.91	9.09
MG	0	0	0	0	0	0	2	141	143	98.6	1.4
Total (pixels)	195	58	148	113	180	49	182	143	1068		
Exatidão do usuário (%)	79.49	89.66	68.92	70.8	78.33	97.96	93.41	98.6		Exatidão total:	83.24%
Erros de inclusão (%)	20.51	10.34	31.08	29.2	21.67	2.04	6.59	1.4		Índice Kappa:	0.8

(b)

Classes			(	Classifica	Total	Exatidão do	Erros de				
Classes	CC	ССТ	CL	CLM	CS	CS/A/CE	CSS	MG	(pixels)	produtor (%)	omissão (%)
СС	153	0	3	1	16	2	7	0	182	84.07	15.93
CCT	3	37	0	0	6	0	7	1	54	68.52	31.48
CL	0	1	122	19	3	4	0	0	149	81.88	18.12
CLM	5	1	31	80	1	0	0	0	118	67.80	32.20
CS	27	0	13	6	123	3	1	0	173	71.09	28.91
CS/A/CE	9	3	0	1	8	29	0	1	51	56.86	43.14
CSS	6	0	0	0	2	0	182	0	190	95.79	4.21
MG	0	7	0	0	0	0	0	144	151	95.36	4.64
Total (pixels)	203	49	169	107	159	38	197	146	1068		
Exatidão do usuário (%)	75.37	75.51	72.19	74.77	77.36	76.32	92.39	98.63		Exatidão total:	81.46%
Erros de inclusão (%)	24.63	24.49	27.81	25.23	22.64	23.68	7.61	1.37		Índice Kanna:	0.78