

MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21b/2016/03.24.17.23-TDI

# CARACTERIZAÇÃO ESPECTRO-SAZONAL DE FITOFISIONOMIAS DO CERRADO E ESTIMATIVA DE BIOMASSA USANDO DADOS DO SENSOR HYPERION/EO-1

Aline Daniele Jacon

Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Lênio Soares Galvão, e João Roberto dos Santos, aprovada em 10 de março de 2016.

URL do documento original: <http://urlib.net/8JMKD3MGP3W34P/3LD4TUP>

> INPE São José dos Campos 2016

## **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 Fax: (012) 3208-6919 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 E INOVAÇÃO INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21b/2016/03.24.17.23-TDI

# CARACTERIZAÇÃO ESPECTRO-SAZONAL DE FITOFISIONOMIAS DO CERRADO E ESTIMATIVA DE BIOMASSA USANDO DADOS DO SENSOR HYPERION/EO-1

Aline Daniele Jacon

Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Lênio Soares Galvão, e João Roberto dos Santos, aprovada em 10 de março de 2016.

URL do documento original: <http://urlib.net/8JMKD3MGP3W34P/3LD4TUP>

> INPE São José dos Campos 2016

Dados Internacionais de Catalogação na Publicação (CIP)

Jacon, Aline Daniele.

J157c

Caracterização espectro-sazonal de fitofisionomias do cerrado e estimativa de biomassa usando dados do sensor hyperion/EO-1 / Aline Daniele Jacon. – São José dos Campos : INPE, 2016. xxiv + 120 p. ; (sid.inpe.br/mtc-m21b/2016/03.24.17.23-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016. Orientadores : Drs. Lênio Soares Galvão, e João Roberto dos Santos.

1. Hiperespectral. 2. Cerrado. 3. Biomassa. 4. PLSR. 5. LDA. I.Título.

CDU 528.8:581.5



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): Aline Daniele Jacon

Título: " CARACTERIZAÇÃO ESPECTRO-SAZONAL DE FITOFISIONOMIAS DO CERRADO E ESTIMATIVA DE BIOMASSA USANDO DADOS 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. Lênio Soares Galvão

Presidente / Orientador(a) / INPE > SJCampos - SP

Dr. João Roberto dos Santos

Orientador(a) / INPE / SJCampos - SP

Dr. Flávio Jorge Ponzoni

N2001

Membro da Banca / INPE / SJCampos - SP

Dra. leda Del' Arco Sanches

Edson Eyji Sano

Nel anco ?

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

Convidedo(a) / EMBRAPA / Brasilia - DF

Este trabalho foi aprovado por:

() maioria simples

🕅 unanimidade

Dr.

"Quem hoje é vivo corre perigo E os inimigos do verde dá sombra ao ar Que se respira e a clorofila Das matas virgens destruídas vão lembrar..."

Matança - Augusto Jatobá

### AGRADECIMENTOS

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) 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, disponibilização de seus recursos e instalações no desenvolvimento deste estudo.

Ao apoio logístico do Instituto Brasília Ambiental (IBRAM) através da Autorização de Pesquisa número 06/2015 (processo nº 391.000.740/2015), para acesso à Estação Ecológica de Águas Emendadas.

A todos os Professores e demais servidores do INPE, pela dedicação e apoio prestado durante o curso de mestrado.

Aos orientadores Dr. Lênio Galvão e Dr. João Roberto por todo conhecimento a mim repassado, pelo rigor, apoio profissional e pessoal e pela parceria, esforço e momentos de descontração na condução do trabalho de campo, assim como em todas as etapas deste estudo. Agradeço pelo aprendizado, amizade e pela oportunidade de trabalhar com os Cerrados de Águas Emendadas.

Ao Sr. José Ferreira Paixão, da Embrapa Cerrados, pelo infinito apoio na fase de campo e identificação das espécies botânicas. Sua experiência e praticidade foram fundamentais na condução deste estudo.

À Embrapa Cerrados pela infraestrutura cedida para o trabalho de campo.

Aos amigos do SERE pelos momentos de aprendizado e descontração. Em especial aos amigos queridos, Aninha, Rodolfo, Sacha e David, não só pelo amparo técnico em todos os momentos que precisei, mas pelo companheirismo, amizade e sintonia. Vocês fizeram a diferença!

Ao João Felipe pela parceria e harmonia do dia a dia, e a sua família que me acolheu e me fez sentir em casa em São José dos Campos. Sou grata por isso e por tudo.

As minhas irmãs da Rep. Mansão, Rani, Bruna e Laura, pelo convívio ao longo desses dois anos.

Aos meus familiares que, mesmo distantes, sempre me deram a força necessária para caminhar.

#### **RESUMO**

O Cerrado é considerado um dos hotspots mundiais, sendo um importante repositório de biodiversidade e com significativo papel no ciclo do carbono. O sensoriamento remoto hiperespectral pode contribuir para melhorar a discriminação de suas fitofisionomias e, sobretudo, melhorar a acurácia das estimativas da biomassa acima do solo (AGB). O objetivo deste estudo é caracterizar a resposta espectro-sazonal das fitofisionomias de Cerrado da Estação Ecológica de Águas Emendadas (ESEC-AE), usando seis imagens de alta resolução espectral do sensor Hyperion/Earth Observing One (EO-1), obtidas nos períodos chuvoso e seco (marco a agosto) de 2014, assim como, estimar a AGB no período seco (imagem de julho). Um levantamento florístico-estrutural foi efetivado em 45 parcelas (0,10 ha cada) na ESEC-AE. Testou-se o uso combinado de diferentes atributos hiperespectrais na discriminação das fitofisionomias com Análise Discriminante Linear (LDA), assim como na estimativa de AGB no período seco com regressão por mínimos quadrados parciais (PLSR). Os atributos utilizados foram: reflectância de 146 bandas do Hyperion; 22 índices de vegetação de bandas estreitas; 10585 razões de reflectância; e a profundidade, largura, área e assimetria de seis importantes bandas de absorção posicionadas em 680 nm (clorofila), 980 nm e 1200 nm (água foliar), 1700 nm, 2100 nm e 2300 nm (lignina e celulose). Os resultados obtidos mostraram que parâmetros estruturais, como diâmetro, altura, densidade e área basal, expressaram adequadamente o gradiente entre as fitofisionomias analisadas. Os valores de AGB medidos/estimados no inventário florestal variaram de 34,46±2,7 t.ha<sup>-1</sup> em parcelas de cerrado denso a 3,98±0,7 t.ha<sup>-1</sup> em parcelas de campo limpo. A discriminação das fitofisionomias por LDA apresentou melhores resultados na análise geral dos atributos e quando realizada no período seco. Os valores do índice Kappa foram de 0,78 e 0,82 para os períodos chuvoso e seco, respectivamente. O ganho na acurácia de classificação, entre períodos, foi considerado significativo de acordo com o teste Z (p<0,01). Considerando a modelagem de biomassa aérea usando PLSR, os melhores resultados também foram obtidos com a análise integrada dos atributos no modelo geral (R<sup>2</sup>=0,66 e RMSE=6,60 t.ha<sup>-1</sup>). Esses valores foram próximos aos encontrados na modelagem por razões de bandas ( $R^2 = 0.65$  e RMSE = 6.63 t.ha<sup>-1</sup>), possivelmente pelo alto número de atributos oriundos desse conjunto de métricas (10585 razões). O uso de dados do sensor Hyperion viabilizou a combinação de diferentes atributos hiperespectrais, não apenas na caracterização/discriminação, como na modelagem da AGB. Essa gama de atributos fornecidos por dados Hyperion pode embasar o desenvolvimento de futuros projetos no bioma Cerrado, utilizando os futuros sensores hiperespectrais orbitais HyspIRI e EnMAP, que irão adquirir dados em faixas de imageamento mais amplas e com melhor relação sinal ruído.

## SPECTRO-SEASONAL CHARACTERIZATION OF CERRADO PHYSIOGNOMIES AND BIOMASS ESTIMATION USING HYPERION / EO-1 DATA

#### ABSTRACT

The Cerrado is considered one of the "hotspots" worldwide. It is an important repository of biodiversity and it plays significant role in the carbon cycle. Hyperspectral remote sensing can help to improve the discrimination of its vegetation types as well as the accuracy of estimates of above-ground biomass (AGB). The aim of this study is to characterize seasonally the spectral response of the Cerrado physiognomies of the Estação Ecológica de Águas Emendadas (ESEC-AE), located in central Brazil, using six images of the hyperspectral Hyperion / Earth Observing One (EO-1) sensor. The images were obtained in the rainy and dry seasons of 2014 (March to August). A floristic-structural survey was performed over 45 plots (0.10 ha each) at the ESEC-AE. The combined use of different hyperspectral attributes was tested for the discrimination of the cerrado physiognomies using Linear Discriminant Analysis (LDA), and for the estimation of AGB in the dry season using Partial Least Squares Regression (PLSR). The attributes used were as follows: the reflectance of 146 bands of Hyperion; 22 narrow-band vegetation indices; 10585 reflectance ratios; and the depth, width, area, and asymmetry of six major absorption bands positioned at 680 nm (chlorophyll), 980 nm and 1200 nm (leaf water), 1700 nm, 2100 nm and 2300 nm (lignin and cellulose). The results showed that the structural parameters, such as diameter, height, density and basal area, expressed the strong gradient between the studied physiognomies. The AGB values measured / estimated in the forest inventory ranged from  $34.46 \pm 2.7$  t ha<sup>-1</sup> for cerrado woodland to  $3.98 \pm 0.7$  t ha<sup>-1</sup> for cerrado grassland. The LDA-derived discrimination between the physiognomies showed the best results when we considered all the attributes in the dry season. The Kappa index ranged from 0.78 to 0.82 for the rainy and dry seasons, respectively. The gain in classification accuracy between the seasons was statistically significant according to the Z-test (p <0.01). For the AGB modeling using PLSR, the best results were also obtained with the integrated analysis of the attributes in the general model ( $R^2 = 0.66$  and RMSE 6.60 t.ha<sup>-1</sup>). These values were similar to those found with reflectance ratios ( $R^2 = 0.65$  and RMSE = 6.63 t ha<sup>-1</sup>), probably due to the high number of attributes derived from this set of metrics (10585 band ratios). The use of Hyperion allowed the combination of different hyperspectral attributes, which were useful not only in the characterization/discrimination of the cerrado physiogniomies, but also in their AGB modeling. These attributes can be tested in future projects in the cerrado using the planned HyspIRI and EnMAP missions, which will acquire hyperspectral images in larger swath width and with better signal-tonoise ratio than that from Hyperion.

## LISTA DE FIGURAS

Figura 2. 1. Princípios da regressão por mínimos quadrados parciais (PLSR) 12
Figura 3. 1. Imagem Rapideye de julho de 2015 e representação das fitofisionomias presentes na Estação Ecológica de Águas Emendadas
Figura 3. 2. Precipitação acumulada mensal (mm) do ano de 2014, 2015 e média desde 2008. Dados da estação meteorológica automática Águas Emendadas (A045), fornecidos pelo Instituto Nacional de Meteorologia (INMET). A área sombreada representa o período seco ao longo do ano
Figura 3. 3. Mapa de solos da Estação Ecológica de Águas Emendadas, segundo Embrapa (1978)
Figura 4. 1. Fluxograma indicando as etapas desenvolvidas no trabalho. AGB refere-se a biomassa acima do solo; PLSR refere-se a regressão por mínimos quadrados parciais.
Figura 4. 2. Amostras de campo sendo coletadas, pesadas e secadas em estufa cedida pela Embrapa Cerrados em Planaltina-DF. (a) alocação das subparcelas dentro da parcela, (b) subparcela de 1 x 1 m, (c) pesagem das amostras e (d) estufa de circulação forçada de ar, onde as amostras foram secas
Figura 4. 3. Representação da sequência de imagens Hyperion, composição 864nm (R), 1548nm (G), 660nm (B), utilizadas no estudo
Figura 4. 4. Representação do espectro de vegetação verde; (a) limites do contínuo sobre a banda de absorção de clorofila (680 nm), (b) parâmetros da banda de absorção após remoção do contínuo
Figura 5. 1. Curva espécie-área obtida por meio das parcelas amostrais inventariadas (n=33). Linhas pontilhadas representam o intervalo de confiança ( $\alpha$ =0,05)
Figura 5. 2. Aspecto visual das fitofisionomias amostradas na Estação Ecológica de Águas Emendadas (ESEC-AE): (a) cerrado denso, (b) cerrado típico, (c) cerrado ralo, (d) campo cerrado, (e) campo sujo, (f) campo limpo
Figura 5. 3. Distribuição diamétrica dos indivíduos arbóreo-arbustivos por fitofisionomia e suas respectivas alturas médias
Figura 5. 4. Box-plot da distribuição dos parâmetros (a) densidade (indivíduos por hectare), (b) altura total média, (c) diâmetro médio (cm), (d) área basal (metros quadrados por hectare). Letras diferentes mostram diferenças significativas entre fitofisionomias, segundo o teste Tukey ( $\alpha = 0,05$ )

Figura 5. 9. Boxplot para comparação das reflectâncias médias no período chuvoso e seco por meio da ANOVA e teste de Tukey (letras diferentes indicam diferença significativa com  $\alpha$ =5%), no (a) vermelho (660 nm), (b) IVP (864 nm) e (c) SWIR 1 (1648 nm).

Figura 5. 16. Projeção dos escores das fitofisionomias analisadas nas duas primeiras funções discriminantes para todos os atributos no período (a) chuvoso e (b) seco...... 66

Figura 5. 18. Correlação entre AGB e Reflectância de 146 bandas do sensor Hyperion. Valores acima de 0,4 e abaixo de -0,4 foram considerados significativos (p<0,05)..... 69

Figura 5. 27. Relação entre biomassa (AGB) e os índices (a) PSSR, (b) PSRI (p<0,05).

Figura 5. 28. Distribuição dos escores nos dois primeiros fatores para os dados de calibração do modelo PLSR com índices de vegetação. Valores entre parênteses explicam a variância de X e de Y, respectivamente, em cada fator analisado. Amostras fora da Elipse de Hotelling T<sup>2</sup> apresentaram comportamentos extremos ( $\alpha = 0,05$ )......78

Figura 5. 32. Coeficientes ajustados para o modelo PLSR com Índices de vegetação. . 80

Figura 5. 35. Correlação entre todas as possíveis razões das 146 bandas do Hyperion e a biomassa (AGB)
Figura 5. 36. Relação entre biomassa (AGB) e a razão de reflectância (a) 1073/691 nm, (b) 1719/1265 nm (p<0,05)
Figura 5. 37. Distribuição dos escores nos dois primeiros fatores para os dados de calibração do modelo razões de banda. Valores entre parênteses explicam a variância de X e de Y respectivamente, em cada fator analisado. Amostras fora da Elipse de Hotelling T <sup>2</sup> , apresentam comportamentos extremos ( $\alpha = 0,05$ )
Figura 5. 38. Comportamento da (a) variância explicada de Y, (b) RMSE em cada fator do modelo razões de banda para calibração e validação
Figura 5. 39. Comparação entre a variância residual de X (limite $F_{crit} = 1,35$ ) e a <i>Leverage</i> (limite = 0,27), verificando a influência de cada amostra na modelagem da AGB pelas 10585 razões de bandas como variáveis independentes X
Figura 5. 40. Valores de AGB observados em relação aos valores preditos na validação cruzada no modelo razões de bandas
Figura 5. 41. Parcela P15 (C) com alta densidade de indivíduos principalmente de <i>Kielmeyera coriácea</i>
Figura 5. 42. Relação da biomassa (AGB) com (a) profundidade e (b) área da banda de absorção da clorofila em 680 nm (p<0,05)
Figura 5. 43. Distribuição dos escores nos dois primeiros fatores para os dados de calibração do modelo PLSR com parâmetros de bandas de absorção. Valores entre parênteses explicam a variância de X e Y, respectivamente, em cada fator analisado. Amostras fora da Elipse de Hotelling T <sup>2</sup> apresentam comportamentos extremos ( $\alpha = 0,05$ )
Figura 5. 44. Distribuição dos <i>loadings</i> nos dois primeiros fatores para os dados de calibração do modelo parâmetros de bandas de absorção. Valores entre parênteses explicam a variância de X e de Y respectivamente, em cada fator analisado
Figura 5. 45. Comportamento da (a) variância explicada de Y, (b) RMSE em cada fator do modelo PLSR com parâmetros de bandas de absorção para calibração e validação cruzada
Figura 5. 46. Comparação entre a variância residual de X (limite $F_{crit} = 1,70$ ) e a <i>Leverage</i> (limite = 0,13), indicando a influência de cada amostra na modelagem da AGB pelos 24 parâmetros das seis bandas de absorção selecionadas como variáveis independentes X
Figura 5. 47. Coeficientes ajustados para o modelo parâmetros de bandas de absorção.
Figura 5. 48. Valores de AGB observados em relação aos valores preditos na validação cruzada do modelo PLSR com parâmetros descritores de bandas de absorção
Figura 5. 49. Parcela de CaL (P39) dominada pela espécie Trembleya parviflora 94

Figura 5. 50. Comportamento da (a) variância explicada de Y, (b) RMSE em ca	ıda fator
do modelo geral para calibração e validação cruzada.	95
Figura 5. 51. Valores de AGB observados em relação aos valores preditos na va	alidação

## LISTA DE TABELAS

Tabela 4. 1. Identificação das parcelas amostradas em cada fitofisionomia 23
Tabela 4. 2. Informações sobre as seis imagens Hyperion/EO-1 utilizadas neste estudo.
Tabela 4. 3. Índices de vegetação utilizados com suas respectivas fórmulas ereferências
Tabela 4. 4. Descrição do número de variáveis independentes e dependente (AGB),assim como o número de amostras utilizadas
Tabela 5. 1. Riqueza de espécies, índice de Shanon (H') e equabilidade de Pielou (J) decada fitofisionomia amostrada na ESEC-AE
Tabela 5. 2. Parâmetros fitossociológicos calculados para as dez espécies de maior IVI, ordenadas por fitofisionomia e em ordem decrescente. As abreviações correspondem a: densidade absoluta (DA), densidade relativa (DR), dominância absoluta (DoA), dominância relativa (DoR), frequência absoluta (FA), frequência relativa (FR) e Índice de Valor de Importância percentual (IVI)
Tabela 5. 3. Valores médios e desvio padrão dos parâmetros biofísicos de cadafitofisionomia amostrada na ESEC-AE.41
Tabela 5. 4. Bandas selecionadas pelo método passo-a-passo para discriminar asfitofisionomias no período chuvoso e no período seco.60
Tabela 5. 5. Índices de Vegetação selecionados pelo método passo-a-passo para discriminar as fitofisionomias no período chuvoso e no período seco
Tabela 5. 6. Parâmetros descritores de bandas de absorção, calculados pelo método do contínuo espectral e selecionados pelo procedimento passo-a-passo para discriminar as fitofisionomias no período chuvoso e no período seco
Tabela 5. 7. Seleção dos melhores atributos para discriminar as fitofisionomias no período chuvoso e seco, considerando o conjunto total de variáveis submetidas para MDA (reflectância, IVs e parâmetros descritores de bandas de absorção)
Tabela 5. 8. Coeficiente de correlação de Pearson (r) para as relações entre os índices de vegetação e a Biomassa (AGB) observada em campo. Valores sombreados indicam correlações significativas ao nível de significância de 0,05
Tabela 5. 9. Coeficiente de correlação (r) para as relações dos parâmetros descritores das bandas de absorção posicionadas em 680 nm, 980 nm, 1200 nm, 1700 nm, 2100 nm e 2300 nm com a biomassa acima do solo (AGB). Os atributos são: P (profundidade da

banda),	L	(largura),	Ar	(área)	e	As	(assimetria).	Valores	sombreados	indicam
correlações significativas ao nível de significância de 0,05							88			
Tabela 5. 10. Desempenho dos modelos PLSR específicos e geral na predição da AGB										
das fitof	ïsio	nomias do	Cerr	ado	••••		-	-		

## LISTA DE SÍMBOLOS, SIGLAS E ABREVIATURAS

AB	-	Área basal
AGB	-	Biomassa seca acima do solo
ARI	-	Anthocyanin Reflectance Index
С	-	Cerrado típico
CaC	-	Campo cerrado
CAI	-	Cellulose Absorption Index
CaL	-	Campo limpo
CaS	-	Campo sujo
CD	-	Cerrado denso
CR	-	Cerrado ralo
CRI1	-	Carotenoid Reflectance Index 1
DA	-	Densidade absoluta
Db	-	Diâmetro a 30 cm da base
DoA	-	Dominância absoluta
DoR	-	Dominância relativa
DR	-	Densidade relativa
ESEC-AE	-	Estação Ecológica de Águas Emendadas
EVI	-	Enhanced Vegetation Index
FA	-	Frequência absoluta
FR	-	Frequência relativa
HT	-	Altura total
IVI	-	Índice de valor de importância
IVP	-	Infravermelho próximo
IVs	-	Índice de vegetação
LDA	-	Análise Discriminante Linear
LWVI2	-	Leaf Water Vegetation Index 2
MCARI	-	Modified Chlorophyll Absorption Ratio Index
MDA	-	Análise Discriminante Múltipla
MG	-	Mata de galeria
MSI	-	Moisture Stress Index
NDII	-	Normalized Difference Infrared Index
NDLI	-	Normalized Difference Lignin Index
NDVI	-	Normalized Difference Vegetation Index
NDWI	-	Normalized Difference Water Index

PCs	- Principais componentes
PLSR	- Regressão por mínimos quadrados parciais
PRI	- Photochemical Reflectance Index
PSRI	- Plant Senescence Reflectance Index
PSSR	- Pigment Specific Simple Ratio
RENDVI	- Red Edge Normalized Difference Vegetation Index
REPI	- Red Edge Position Index
RVSI	- Red-Edge Vegetation Stress Index
SIPI	- Structure Insensitive Pigment Index
SWIR 1	- Infravermelho de ondas curtas 1
SWIR 2	- Infravermelho de ondas curtas 2
VARI	- Visible Atmospherically Resistant Index
VIg	- Visible Green Index
VOG	- Vogelmann Red Edge Index
WBI	- Water Band Index

## SUMÁRIO

## <u>Pág</u>.

1.	INTRODUÇÃO	. 1
1.1.	Hipótese de trabalho	. 4
1.2.	Objetivos	. 4
2.	FUNDAMENTAÇÃO TEÓRICA	. 5
2.1.	Sensoriamento remoto hiperespectral	. 5
2.2.	Análise Discriminante Linear (LDA)	. 6
2.3.	Regressão por Mínimos Quadrados Parciais (PLSR)	. 9
3.	ÁREA DE ESTUDO	15
4.	METODOLOGIA DE TRABALHO	21
4.1.	Seleção da área de estudo	21
4.2.	Aquisição e tratamento dos dados de campo	22
4.2.1.	Inventário florestal	22
4.2.2.	Caracterização florística e estrutural das fitofisionomias	24
4.3.	Seleção e pré-processamento das imagens Hyperion	26
4.4.	Geração de atributos hiperespectrais	28
4.5.	Caracterização e discriminação espectro-sazonal das fitofisionomias	31
4.6.	Modelagem da AGB por PLSR	33
5.	RESULTADOS E DISCUSSÃO	37
5.1.	Caracterização florística e estrutural das fitofisionomias	37
5.2.	Caracterização espectro-sazonal das fitofisionomias	47
5.2.1.	Análise sazonal por atributos hiperespectrais	48
5.2.2.	Discriminação de fitofisionomias por análise discriminante múltipla (MDA)	59
5.2.2.1.	Atributos de reflectância	59
5.2.2.2.	Índices de vegetação (IVs)	61
5.2.2.3.	Parâmetros de bandas de absorção	63
5.2.2.4.	Análise conjunta de todos os atributos	65
5.3.	Modelagem da AGB com atributos hiperespectrais e PLSR	67
5.3.1.	Modelagem da AGB com Reflectância	69

5.3.1.1.	Análise exploratória da reflectância	69			
5.3.1.2.	Modelagem PLSR da reflectância	70			
5.3.2.	Modelagem da AGB com Índices de Vegetação (IVs)	76			
5.3.2.1.	Análise exploratória IVs	76			
5.3.2.2.	Modelagem PLSR dos IVs	78			
5.3.3.	Modelagem da AGB com razões de bandas	82			
5.3.3.1.	Análise exploratória das razões de bandas	82			
5.3.3.2.	Modelagem PLSR das razões de bandas	84			
5.3.4.	Modelo da AGB com parâmetros de bandas de absorção	87			
5.3.4.1.	Análise exploratória das bandas de absorção	87			
5.3.4.2.	Modelagem PLSR com parâmetros de bandas de absorção	89			
5.3.5.	Modelagem da AGB com PLSR e todos os atributos	94			
6.	CONCLUSÕES E RECOMENDAÇÕES	99			
REFER	ÊNCIAS BIBLIOGRÁFICAS 1	103			
APÊND	DICE A - MÉDIA, DESVIO PADRÃO E PORCENTAGEM	DE			
MUDA	NÇA PARA CADA ÍNDICE DE VEGETAÇÃO CALCULADO PARA	0			
PERÍO	DO CHUVOSO E SECO1	115			
APÊND	DICE B - MATRIZ DE CONFUSÃO PARA CADA CONJUNTO	DE			
MÉTRICAS HIPERESPECTRAIS EM CADA PERÍODO					

#### 1. INTRODUÇÃO

No mundo, o ambiente savânico é um importante repositório de biodiversidade (FURLEY, 1999), desempenhando papel essencial no ciclo do carbono, com aproximadamente 30% da produção primária líquida terrestre (FIELD et al., 1998). Dada à alta diversidade biológica e ao alto risco de extinção, o Cerrado é considerado um dos *hotspots* mundiais (MYERS et al., 2000). Segundo Sano et al. (2008), aproximadamente 39% das áreas nativas de Cerrado estão sob algum tipo de pressão de uso da terra.

O Cerrado é composto por um mosaico de fitofisionomias que variam ao longo de um gradiente de campos abertos até formações de estrutura florestal. Esse gradiente vegetal é determinado por um conjunto de fatores, podendo-se destacar a disponibilidade de água e nutrientes no solo e a marcante sazonalidade das chuvas (FELFILI et al., 2005b). Essa riqueza de fitofisionomias, verticalmente estruturadas por espécies herbáceas, arbustivas e arbóreas, foi descrita por Ribeiro e Walter (1998) e separadas em três formações fitofisionômicas gerais: formações florestais (mata ciliar, mata de galeria, mata seca e cerradão), savânicas (cerrado s*ensu stricto*, parque cerrado, palmeiral e vereda) e campestres (campo sujo, campo rupestre e campo limpo).

As variabilidades fisionômicas-estruturais existentes entre fitofisionomias do Cerrado, assim como suas características fenológicas, produzem mudanças na resposta espectral medida por sensores remotos. Entretanto, a discriminação de fitofisionomias tem se apresentado como um grande desafio, principalmente em formações espectralmente similares, como as formações campestres (campo sujo e campo limpo) e as formações com predomínio de indivíduos arbóreo-arbustivos (campo cerrado e cerrado *sensu stricto*) (FERREIRA et al., 2007).

Devido à complexidade das diferentes formações de Cerrado, os resultados obtidos com sensores multiespectrais e métodos de processamento desenvolvidos para esse tipo de imagem têm tido sucesso moderado quanto à capacidade discriminatória e de mapeamento (FERREIRA et al., 2004; LIESENBERG et al., 2007). Diante desse cenário, o advento de sensores hiperespectrais constitui oportunidade para o melhor entendimento sobre o processo de interação da radiação eletromagnética com a

cobertura vegetal, contribuindo para o aprimoramento da discriminação, assim como para a melhoria das estimativas de parâmetros biofísicos como a biomassa acima do solo (AGB).

Como parte dos estudos preparatórios para o lançamento da missão hiperespectral alemã EnMAP (*Environmental Mapping and Analysis*), pesquisadores de diversos países do denominado *EnMAP Scientific Advisory Group* (EnSAG) identificaram o Cerrado como um dos *hotspots* mundiais de maior biodiversidade e interesse da missão. Eles têm destacado a importância de mapear e monitorar suas fitofisionomias e de quantificar sua biomassa usando dados da futura missão EnMAP (LEITÃO et al., 2015). O EnMAP será lançado em 2017 e irá adquirir imagens em mais de 200 bandas espectrais estreitas (10 nm de largura entre 400 e 2500 nm). O instrumento irá operar com 30 km de faixa de imageamento, 30 m de resolução espacial e alta relação sinal/ruído (SNR) no infravermelho de ondas curtas (SWIR - shortwave infrared) (GUANTER et al., 2015). Diante da ausência de dados EnMAP, a maior parte dos estudos preparatórios têm lançado mão de dados hiperespectrais do sensor Hyperion/Earth Observing One (EO-1).

O Hyperion/EO-1 é o instrumento que melhor representa o estado-da-arte do sensoriamento remoto hiperespectral orbital, possuindo, contudo, especificações técnicas inferiores às do futuro EnMap. Contudo, demonstra ser eficaz na simulação de análises multispectrais/hiperspectrais de variados ecossistemas.

A grande quantidade de bandas espectrais do Hyperion e a gama de atributos gerados a partir de seus dados (índices de vegetação, razões de banda, parâmetros de bandas de absorção e etc.) resultam em alta dimensionalidade dos dados de entrada para fins de classificação (VYAS et al., 2011). Para evitar o efeito Hughes, resultante da redução na acurácia de classificação com o aumento da dimensionalidade dos dados (HUGHES, 1968), o uso de classificadores paramétricos normalmente é precedido de procedimentos de seleções de atributos. Uma das técnicas mais utilizadas para diferenciar classes de difícil separação, que requer seleção *a priori* de atributos, é Análise Discriminante Linear (LDA - *Linear Discriminant Analysis*). LDA é uma técnica estatística multivariada que busca a discriminação e, ou, alocação de novas observações em classes previamente definidas (JOHNSON; WICHERN, 1988). São muitos os trabalhos que fazem uso dessa técnica, com objetivos variados, mas todos

visam determinar o conjunto de atributos hiperespectrais mais sensíveis às características para a melhor discriminação das formações vegetais (FERET; ASNER, 2013; GALVÃO et al., 2005; GALVÃO et al., 2009ab; ROTH et al. 2015b; VYAS et al., 2011).

Trabalhos envolvendo a discriminação de fitofisionomias de Cerrado com dados hiperespectrais e uso de LDA, visando à identificação dos atributos espectrais de melhor poder de diferenciação das classes (p.ex., reflectância, razões de reflectância, índices de vegetação e parâmetros descritores de bandas de absorção), não têm sido reportados na literatura. Poucos foram os trabalhos que testaram o potencial dos dados hiperespectrais com diferentes classificadores no ambiente do Cerrado (FERREIRA et al., 2007; MIURA et al., 2003; SOUZA et al., 2010). De fato, trabalhos comparando o desempenho de classificadores como o LDA com diferentes atributos hiperespectrais, obtidos em períodos sazonais distintos (chuvoso e seco) no Cerrado, ainda não foram publicados na literatura.

Um dos parâmetros biofísicos da vegetação de maior interesse por parte da comunidade científica na última década é a biomassa acima do solo (AGB - above-ground biomass). Sua modelagem espacial é relevante para os estudos de emissão e re-absorção de carbono em escala global e, consequentemente, para a elaboração de inventários com dados mais confiáveis para discussão de programas internacionais destinados à redução de emissões de gases de efeito estufa (LEI et al., 2012; LAURIN et al., 2014). Segundo pesquisadores do EnSAG, a estimativa da AGB é um desafio em áreas extensas e complexas, como é o caso do Cerrado, necessitando assim do constante desenvolvimento de metodologias que busquem ganhos de precisão em sua estimativa (GUANTER et al., 2015; LEITÃO et al., 2015). Uma das abordagens dominantes na estimativa de AGB a partir de dados hiperespectrais é a regressão por mínimos quadrados parciais (PLSR - Partial Least Squares Regression). PLSR consegue lidar com a forte colinearidade dos dados causada pelo grande número de bandas espectrais e atribudos hiperespectrais gerados. Essa técnica tem apresentado resultados satisfatórios em estudos relacionados a estimativas de biomassa a partir de dados hiperespectrais (CHEN et al., 2012; CHO et al., 2007; CLEVERS et al., 2007; HANSEN;

SCHJOERRING, 2003; LAURIN et al., 2014; LEI et al., 2012; MARABEL; ALVAREZ-TABOADA, 2013; TZANAKAKIS et al., 2014).

#### 1.1. Hipótese de trabalho

O presente estudo é baseado na hipótese de que a análise integrada de diferentes conjuntos de atributos hiperespectrais melhora a discriminação de fitofisionomias do Cerrado, assim como, a modelagem da AGB quando comparado à análise isolada de conjuntos de atributo.

#### 1.2. Objetivos

O objetivo principal do trabalho é caracterizar a resposta sazonal de fitofisionomias do Cerrado na ESEC-AE por meio de imagens de alta resolução espectral do sensor Hyperion/EO-1, verificando a possibilidade do uso combinado de diferentes atributos hiperespectrais para a discriminação espectral e a estimativa de biomassa no período seco.

Para tanto, os seguintes objetivos específicos foram propostos:

- a. Caracterizar florística e estruturalmente as fitofisionomias do Cerrado amostradas por meio de inventário florestal na Estação Ecológica de Águas Emendadas - DF;
- b. Caracterizar a resposta espectro-sazonal e avaliar a capacidade discriminatória das fitofisionomias do Cerrado por meio de atributos hiperespectrais através da técnica ou procedimento LDA;
- *c*. Testar a utilização combinada de diferentes atributos hiperespectrais para compor um modelo de estimativa de biomassa no período seco, utilizando o procedimento estatístico PLSR.

#### 2. FUNDAMENTAÇÃO TEÓRICA

#### 2.1. Sensoriamento remoto hiperespectral

Sensores hiperespectrais são caracterizados por registrarem a radiação eletromagnética em muitas bandas estreitas e contíguas, ao longo do espectro eletromagnético, por meio de espectrômetros a bordo de aeronaves ou satélites. Essa forma de aquisição dos dados torna possível a extração de informações mais detalhadas sobre a resposta espectral dos alvos, permitindo a inferência sobre a composição dos mesmos (SCHAEPMAN et al., 2009).

A comunidade científica tem demonstrado grande interesse na elaboração de metodologias utilizando dados hiperespectrais em diversas áreas do conhecimento, especialmente em estudos que possibilitam a estimativa de parâmetros biofísicos e bioquímicos da vegetação. Dentre algumas aplicações, pode-se citar estudos sobre a discriminação de estágios sucessionais em floresta tropical (GALVÃO et al., 2009a; MILLÁN et al., 2014); estimativa de parâmetros bioquímicos em florestas tropicais (ASNER; MARTIN, 2008; VYAS; KRISHNAYYA, 2014); dinâmica de parâmetros hiperespectrais e suas relações com variáveis hidroclimáticas (TAGESSON et al., 2015); variações sazonais na fenologia e produtividade de floresta tropical seca (CHRISTIAN et al, 2015); estimativa de conteúdo de água em dossel de savanas (FERREIRA et al., 2011); relações e estimativas de biomassa acima do solo em diferentes tipos de vegetação (LATIFI et al., 2015; LAURIN et al., 2014; LEI et al., 2012; PONZONI et al., 2010); discriminação de fitofisionomias do Cerrado (SOUZA et al, 2010); discriminação de variedades de soja e cana-de-açúcar (BREUNIG, et al., 2011; GALVÃO et al., 2005; 2009b); e detecção de doenças em culturas agrícolas (APAN et al., 2004).

Diante da escassez de sensores orbitais utilizados em trabalhos de sensoriamento remoto hiperespectral, os dados oriundos do sensor Hyperion vem servindo como base, a mais de uma década (lançado no ano 2000), para inúmeros trabalhos em diferentes áreas de aplicação. Este sensor está a bordo do satélite Earth Observing One (EO-1) e faz parte do programa *—New Millenium Program da National Aeronautics and Space Administration* (NASA). Este satélite se encontra em uma altitude de 705 km de

altitude, tendo como objetivo o aprimoramento na busca por mais informações sobre a superfície terrestre. O Hyperion adquire dados de 426 a 2395 nm em 242 bandas estreitas e contíguas, das quais apenas 196 são radiometricamente calibradas, com 10 nm de largura. A resolução espacial é de 30 metros e a faixa de imageamento é de 7,7 km (PEARLMAN et al., 2003). A resolução temporal é de 16 dias, porém, pode ser reduzida pelo processo de apontamento, permitindo a aquisição de várias imagens ao longo de um mês. O sistema de varredura do sensor Hyperion opera em modo *pushbroom* e possui um telescópio e dois espectrorradiômetros imageadores: um na região do visível e infravermelho próximo (IVP) e outro na região do infravermelho de ondas curtas (SWIR). Um filtro dicroico direciona as bandas de 400 a 1000 nm para um espectrorradiômetro e as bandas de 900 a 2500 nm para outro. Os espectrorradiômetros se sobrepõem de 900 a 1000 nm, permitindo a intercalibração entre eles. Os dados são quantificados em 16 bits (UNGAR et al., 2003).

Segundo Galvão et al. (2009b), o sensor Hyperion pode fornecer estimativas importantes sobre propriedades biofísicas e bioquímicas, como por exemplo, clorofila, conteúdo de água nas folhas, lignina, celulose, índice de área foliar (LAI - *Leaf area index*), etc. Por outro lado, a pobre relação sinal-ruído do sensor, especialmente no SWIR, é um obstáculo para a medição adequada dessas feições sem a interferência de ruídos. O processo de apontamento que pode reduzir o processo de revisita de 16 dias permite adquirir imagens fora do nadir, contribuindo para estudos que envolvam a influência da geometria de aquisição de dados em imagens hiperespectrais, temática ainda pouco explorada na maioria das aplicações (MOURA et al., 2012).

#### 2.2. Análise Discriminante Linear (LDA)

O uso de sensoriamento remoto hiperespectral na classificação da vegetação gera um problema clássico: a alta dimensionalidade dos dados de entrada (VYAS et al., 2011). Muitas técnicas são utilizadas na resolução desse problema, pois classificadores paramétricos, como LDA, pressupõe seleção de atributos antes da classificação. São muitos os trabalhos que fizeram uso da LDA na análise da vegetação a partir de atributos hiperespectrais. Por exemplo, Galvão et al. (2005) utilizaram LDA na discriminação de cinco variedades de cana-de-açúcar no sudeste do Brasil, utilizando diferentes métricas hiperespectrais. Galvão et al. (2009a) utilizaram esta técnica com

dados do sensor hiperespectral *Compact High Resolution Imaging Spectrometer* (CHRIS)/PROBA na discriminação de diferentes estágios de sucessão secundária em abordagem multiangular na Amazônia brasileira. Papes et al. (2013) utilizaram LDA, dentre outras técnicas, na classificação de diferentes espécies em floresta de várzea na Amazônia Peruana. Vyas et al. (2011) testaram LDA na seleção de bandas para classificar diferentes espécies em mata seca na India. Shang e Chisholm (2013) classificaram espécies nativas da Austrália com LDA, dentre outras técnicas, de forma similar ao feito por Feret e Asner (2013) com espécies de floresta tropical no Havaí. Roth et al. (2015a) utilizaram LDA na classificação de diferentes tipologias vegetais dos Estados Unidos em abordagem multi-escala. Roth et al. (2015b) concluíram que LDA, quando comparado ao MESMA (*Multiple Endmember Spectral Mixture Analysis*), teve desempenho superior na classificação da vegetação de diferentes ecossistemas americanos.

LDA é uma técnica multivariada utilizada para analisar a relação entre a variável dependente qualitativa, ou categórica (grupos), e as variáveis independentes quantitativas (HAIR et al., 2005). O objetivo principal dessa técnica é identificar as variáveis que diferenciam ou discriminam os grupos, permitindo assim, previsões sobre uma nova observação em função de suas características. Para alcançar esse objetivo, produzem-se combinações lineares (funções discriminantes) das variáveis independentes que ampliam a discriminação dos grupos descritos pelas variáveis dependentes. Assim, são definidas regras de classificação dos elementos em cada grupo. A discriminação é obtida estabelecendo-se pesos (escores). Estes são atribuídos a cada variável independente e corrigidos para as inter-relações entre todas as variáveis (FÁVERO et al., 2009).

Quando há interesse em estudar somente dois grupos de variáveis dependentes, a técnica é chamada de Análise Discriminante Simples. No entanto, em muitos casos, há o interesse na discriminação entre mais de dois grupos, sendo assim denominada de Análise Discriminante Múltipla. Caso haja um grande número de variáveis independentes e o intuito é selecionar um subconjunto útil para prever a variável dependente, é indicada a utilização da LDA com seleção das variáveis independentes ou atributos (PESTANA; GAGEIRO, 2000).

Em algumas situações, como é o caso deste trabalho, pode existir um número de variáveis independentes muito grande, resultando em alta dimensionalidade dos dados, também conhecido como efeito Hughes (HUGHES, 1968). Nesse caso, é desejável selecionar um número relativamente menor de variáveis, que contenham informações relevantes (JOHNSON; WICHERN, 1988). O mais popular dentre os procedimentos de seleção de variáveis é o *stepwise* (passo-a-passo). Neste procedimento, a primeira variável incluída na análise possui o maior valor aceitável para o critério de seleção (estatística *F*). Após a inclusão da primeira variável, o valor do critério é redefinido para todas as variáveis não incluídas no modelo. Assim, em cada passo, é examinada a possibilidade de inclusão de novas variáveis no modelo, bem como da remoção daquelas já incluídas. Valores de probabilidade F são normalmente considerados neste procedimento como critério para a inclusão e remoção das variáveis (HUBERTY, 1984).

Dentre os métodos para seleção de variáveis, podem-se destacar: Método lambda de Wilks; V de Rao; Distância de *Mahalanobis* ( $D^2$ ); Teste F entre grupos e Soma da Variância não explicada (BRAGA et al., 1999). A Distância de *Mahalanobis* ( $D^2$ ) foi utilizado neste estudo por se tratar de um dos métodos mais utilizados em estudos hiperespectrais. Quando a distância de *Mahalanobis* é usada como critério para seleção de variáveis, ela é calculada primeiro, sendo a variável que apresentar o maior  $D^2$  para os dois grupos mais similares (menor  $D^2$  inicialmente) a selecionada para inclusão no modelo (COOLEY; LOHNES, 1971).

O próximo passo, após a seleção das variáveis discriminantes (explanatórias), é a identificação das funções discriminantes. As funções lineares discriminantes são obtidas a partir da extração dos autovetores da matriz W<sup>-1</sup>B (intra e inter-grupos), constituindo combinações lineares das variáveis explanatórias que maximizam a razão entre as dispersões intergrupos e intragrupos (B/W). Dadas as p variáveis e g grupos, é possível estabelecer o número máximo de funções discriminantes que podem ser extraídas como (g-1) ou p, o que for menor.

As funções discriminantes são derivadas em ordem de importância decrescente. A primeira representa a melhor combinação linear possível das variáveis iniciais, ou seja, ela extrai o máximo possível da variância intergrupos existente no espaço inicial; a

segunda extrai o máximo possível da variância remanescente, com restrição de ser ortogonal à primeira; e assim, sucessivamente, são extraídos vetores mutuamente ortogonais, até esgotar a variância contida na matriz W<sup>-1</sup>B. Alguns critérios podem ser usados para avaliar a importância relativa de cada função discriminante na diferenciação dos grupos. Dentre eles, a porcentagem relativa dos autovalores ( $\lambda$ ); o coeficiente de correlação canônica (R); e o teste de qui-quadrado (X<sup>2</sup>) (COOLEY; LOHNES, 1971).

Das funções discriminantes, obtêm-se os escores discriminantes para cada amostra. O centroide do grupo representa a média de todos os escores dentro de um grupo. O poder discriminatório das variáveis explanatórias é consequência da distância entre os centroides dos diversos grupos no espaço discriminante. O grau de dispersão dentro do grupo é revelado pela distância entre cada observação e o centroide do grupo. Assim, é possível identificar grupos mais coesos e observações classificadas erroneamente (HAIR et al., 2005). O cálculo dos escores de novas observações nas funções discriminantes permite identificar o grupo ao qual as observações deveriam ser incorporadas, com menor probabilidade de erro.

### 2.3. Regressão por Mínimos Quadrados Parciais (PLSR)

A forte multicolinearidade causada por um número de amostras muito menor do que o número de variáveis independentes (X) resulta em elevada correlação entre os preditores e modelos não confiáveis. Uma abordagem que vem ganhando espaço e que pode ser utilizada para evitar este problema é a PLSR (MARABEL; ALVAREZ-TABOADA, 2013). Essa técnica tem sido amplamente utilizada em estudos relacionados à análise da vegetação a partir de dados hiperespectrais (ASNER; MARTIN, 2008; CHEN et al., 2012; CHO et al., 2007; CLEVERS et al., 2007; HANSEN; SCHJOERRING, 2003; LAURIN et al., 2014; LEI et al., 2012; LIU; GUO, 2014; MARABEL; ALVAREZ-TABOADA, 2013; PEERBHAY et al., 2013; VYAS; KRISHNAYYA, 2014).

Regressão PLSR é uma técnica multivariada bilinear que generaliza e combina características de análise por componentes principais (PCA - *Principal component analysis*) e regressão linear múltipla (MLR - *Multiple Linear Regression*). Originou-se

das ciências sociais, especificamente das ciências econômicas (WOLD, 1966), mas tornou-se popular pela primeira vez em quimiometria (WOLD, 2001). Seu objetivo é prever ou analisar um conjunto de variáveis dependentes (Y), em função de um conjunto de variáveis independentes (X) (HUBERT; VANDEN- BRANDEN, 2003). Os métodos de modelagem bilinear são projetados para situações onde existe colinearidade entre as variáveis originais. Informações comuns nas variáveis originais são usadas para construir novas variáveis, chamadas de variáveis latentes, fatores ou ainda componentes principais (PC - *Principal component*). Essas são ortogonais, não correlacionados e visam o melhor poder preditivo. PLSR está intimamente relacionado com a regressão por componentes principais (PCR - *Principal component regression*). A principal diferença é que PLSR utiliza as informações de ambas as variáveis X e Y de forma interativa para ajustar o modelo, diferentemente da PCR, que decompõe X e Y isoladamente. Dessa forma, PLSR muitas vezes precisa de menos PCs para alcançar a solução ótima, porque o foco é sobre a projeção das variáveis Y e não em alcançar a melhor projeção de X como no PCR (GELADI; KOWALSKI, 1986).

Em PLSR, as matrizes X e Y são decompostas simultaneamente em uma soma de h fatores, como nas Equações 2.1 e 2.2:

$$X = TP' + E = \sum t_h p'_h + E \tag{2.1}$$

$$Y = UQ' + F = \sum u_h q'_h + F \tag{2.2}$$

onde  $T \in U$  são as matrizes de escores das matrizes  $X \in Y$ , respectivamente;  $P \in Q$  são as matrizes dos *loadings* das matrizes  $X \in Y$ , respectivamente; e  $E \in F$  são os resíduos.

Basicamente, os escores são interpretados da mesma forma como escores PCA. São as coordenadas das amostras ao longo das componentes do modelo. O único recurso novo na PLSR é que dois conjuntos diferentes de componentes podem ser considerados. *T*-escores são as novas coordenadas dos pontos de dados no espaço *X*, calculado de tal maneira que eles capturaram a parte da estrutura em *X*, que é mais preditiva para *Y*. *U*-escores resumem a parte da estrutura em que *Y* é explicado por *X* ao longo de uma determinada componente do modelo. Estes não existem na PCR. A relação entre *T* e *U*-
escore é um resumo da relação entre *X* e *Y* ao longo de uma específica componente do modelo (GELADI; KOWALSKI, 1986).

Os loadings expressam o quanto cada variável X e Y estão relacionadas com a componente do modelo resumido pelo T-escores. Os loadings são interpretados de forma diferente no espaço X e Y. P-loadings expressam quanto cada variável X contribui para uma componente específica do modelo, podendo ser usado exatamente da mesma forma como na PCA. Direções determinadas pelas projeções das variáveis X são usadas para interpretar o significado da localização de um ponto de dados projetada em um terreno t-escores, em termos de variações no X. Q-loadings expressam a relação direta entre as variáveis Y e as t-escores. Assim, as direções determinadas pelas projeções das variáveis Y podem ser utilizadas para interpretar o significado da localização de um ponto de dados projetada em um terreno t-escores, em termos de variação da amostra em Y. Os dois tipos de loadings podem ser plotados em um único gráfico para facilitar a interpretação dos t-escores em relação a direções de variação, tanto em X como em Y. Deve-se salientar que, ao contrário do *loadings* PCA, os fatores de peso da PLSR não são normalizados, de modo que P e Q-loadings não compartilham de uma escala comum. Assim, as suas direções são mais fáceis de interpretar do que os seus comprimentos. As direções só devem ser interpretadas desde que as variáveis X ou Y sejam suficientemente consideradas, o que pode ser verificado usando a variância explicada ou variância residual (CAMO, 2013).

Tal como em todos os modelos de regressão, o objetivo da PLSR é minimizar os resíduos F tanto quanto possível e, ao mesmo tempo, ter uma representação da relação entre X e Y passível de generalização (validação). Existe uma relação interior que resulta da interdependência das variáveis Y sobre X. As relações internas e externas são construídas usando o algoritmo NIPALS (ABDI, 2007). Devido à ligação interior, os componentes principais utilizados para a representação de X e Y não podem ser calculados separadamente. Em outras palavras, ao construir o modelo PLSR, as relações externas devem cooperar na construção do modelo como um todo, ou seja, construir um modelo preditivo capaz de relacionar X a Y. Isto significa que as relações exteriores não podem ser tratadas separadamente, mas sim tratadas como partes de um mesmo problema (Equação 2.3) (GELADI; KOWALSKI, 1986).

$$\mathbf{u}_h = b_h t_h \tag{2.3}$$

para *h* variáveis latentes, sendo que os valores de  $b_h$  são agrupados na matriz diagonal B, que contém os coeficientes de regressão entre a matriz de escores U de Y e a matriz de escores *T* de X. A melhor relação linear possível entre os escores desses dois blocos é obtida através de pequenas rotações das variáveis latentes dos blocos de X e Y.

A matriz Y pode ser calculada de  $u_h$  pela Equação 2.4 a seguir:

$$Y = TBQ' + F \tag{2.4}$$

E a concentração de novas amostras prevista a partir dos novos escores, T\*, substituídos na Equação anterior (Equação 2.5).

$$Y = T^* B Q \tag{2.5}$$

Um resumo dos princípios da regressão PLS pode ser observado na Figura 2.1.



Figura 2. 1. Princípios da regressão por mínimos quadrados parciais (PLSR).

Fonte: Böhm et al. (2012). 12 Nesse processo, um passo crítico é estabelecer o número correto de fatores a serem utilizados no modelo (WOLD, 1978). Os fatores (PCs) podem ser escolhidos de diferentes maneiras. O número de PCs a serem utilizados é uma propriedade muito importante de um modelo PLSR. Embora seja possível calcular o máximo de fatores PLSR para o modelo, nem todos eles são normalmente usados. As principais razões para isso são que os dados medidos nunca estão livres de ruídos e alguns dos fatores de ordem inferior só irão descrever ruído. Dessa forma, é comum deixar de fora PCs de ordem inferior, pois podem resultar em problemas de colinearidade. A primeira PC correspondente ao maior autovalor é, por definição, a direção no espaço de X que descreve a máxima quantidade de variância das amostras. Quando toda a variância de um conjunto de amostras não puder ser explicada por apenas uma PC, uma segunda componente ortogonal a primeira será utilizada, e assim por diante. Após a modelagem, teoricamente, a matriz dos quadrados dos resíduos deverá conter apenas a variância não explicada associada ao ruído (GELADI; KOWALSKI, 1986).

Existem métodos com diferentes critérios para decidir o número de PCs a serem utilizados. Dentre eles, destaca-se o método por validação cruzada (*cross validation*). Este método define o número ótimo de PCs por meio da minimização da raiz quadrada do erro quadrático médio (RMSE - *root mean square error*) da predição. O critério para adicionar um novo fator ao modelo é a redução do RMSE em pelo menos 2% (KOOISTRA et al., 2004). Na validação cruzada, as mesmas amostras são utilizadas tanto na construção quanto na validação do modelo. A validação cruzada aplicada neste trabalho foi a do tipo *"leave-one-out"* (CLEVERS et al., 2007; MARABEL; ALVAREZ-TABOADA, 2013). Esse método consiste em remover uma única amostra da base de dados e o modelo selecionado é ajustado a partir das amostras remanescentes. O processo é repetido até que todas as amostras tenham sido utilizadas para predição. No passo seguinte, todos os resíduos são combinados para computar a variância residual da validação. O valor do RMSE e uma calibração final são então obtidos com todas as amostras (EFRON; GONG, 1983).

## 3. ÁREA DE ESTUDO

Distante aproximadamente 50 km do centro de Brasília e a 5 km do centro de Planaltina, a Estação Ecológica de Águas Emendadas (ESEC-AE) foi criada pelo Decreto nº 771, de 12 de agosto de 1968, inicialmente como Reserva Biológica. Posteriormente, foi elevada à condição de Estação Ecológica pelo Decreto do Governo do Distrito Federal nº 11.137 de 16 de junho de 1988 (ALBUQUERQUE, 2008). Estação Ecológica é definida como uma Unidade de Conservação (UC) de proteção integral, ou seja, os usos permitidos restringem-se às atividades de uso indireto, como pesquisa científica e educação ambiental, de acordo com o que dispuser o plano de manejo da unidade ou regulamento específico. Essa categoria de manejo procura preservar a biodiversidade com a menor interferência antrópica possível, limitando as ações ao mínimo necessário (HOROWITZ; JESUS, 2008). Hoje, sob responsabilidade do Instituto Brasília Ambiental (IBRAM), compreende uma área de 10.547 ha, correspondendo a 17,6% das áreas protegidas do DF, sob a categoria de Unidades de Conservação de Proteção Integral, adquirindo extrema importância perante a dinâmica de uso e ocupação do solo na região (GEO LÓGICA/ECOTECH, 2009).

A ESEC-AE é uma unidade de conservação diretamente relacionada com a água em função do fenômeno que originou a sua criação. As águas que ali brotam, numa vereda de seis quilômetros de extensão, correm em duas direções opostas. A parte norte da Estação, para onde drena o Córrego Vereda Grande, localiza-se na Bacia Hidrográfica do Rio Maranhão, que contribui para a formação dos corpos hídricos da Bacia Hidrográfica Tocantins/Araguaia. A parte sul, para onde drena o Córrego Brejinho, localiza-se na Bacia Hidrográfica do Rio São Bartolomeu, que contribui para a formação dos corpos hídricos da Bacia Hidrográfica do Rio Paraná. Elas banham, além do Distrito Federal, os estados de Goiás, Minas Gerais, Mato Grosso do Sul, São Paulo e Paraná, além dos países vizinhos Paraguai, Argentina e Uruguai, percorrendo mais de 5.000 km para o norte e para o sul (CARVALHO, 2008).

A rica vegetação presente na ESEC-AE também é bem cuidada. Segundo Felfili et al. (2008), as fitofisionomias que ocorrem na ESEC-AE constituem: 1) Campos, com o predomínio de gramíneas e arbustos, caracterizados por diversas tipologias, denominados campo limpo, quando as árvores são praticamente ausentes, e campo sujo,

quando a cobertura arbustiva se aproxima de 10% da área ocupada por vegetação; 2) Cerrado *sensu stricto*, que ocorre em extensas áreas sobre solos profundos e bem drenados, caracterizado por uma camada herbácea com predominância de gramíneas e por uma camada lenhosa, que varia de 3 a 5 m de altura, com cobertura arbórea de 10 a 60%; 3) Matas de galeria, que formam uma rede florestal perenifólia ao longo dos cursos d'água, apresentando cobertura arbórea de 80 a 100%, sendo comum a ocorrência de árvores emergentes ao dossel que atinge de 20 a 30 m de altura, contendo espécies endêmicas, espécies da floresta amazônica, da Mata Atlântica e das matas da Bacia do Rio Paraná, além de espécies de cerrado *sensu stricto* e de florestas estacionais do Brasil Central; 4) Veredas, que são formações dominadas por espécies adaptadas para o desenvolvimento em solos permanentemente alagados como buritis (*Mauritia flexuosa*) e presença de camada herbácea de gramíneas e ciperáceas.

No entanto, para o presente estudo, com base no mapa de vegetação do plano de manejo (GEO LÓGICA/ECOTECH, 2009) e também na campanha de campo descrita na seção seguinte e na análise de uma imagem Rapideye de 2015, obtida simultaneamente ao período de campo, as fitofisionomias foram subdivididas em: campo limpo e campo sujo (formações campestres); campo cerrado, cerrado ralo, cerrado típico e cerrado denso (formações savânicas com progressivo adensamento de indivíduos arbóreo-arbustivos); e mata de galeria (formação florestal). Outras feições também presentes na área como veredas, regeneração e solo exposto, também constam do levantamento temático, conforme ilustrado na Figura 3.1, porém não foram analisadas nesse estudo. A área correspondente a Lagoa Bonita, parte integrante desta Unidade de Conservação, não foi representada. O Plano de Manejo da ESEC-AE foi executado pelo Consórcio de Empresas Geo Lógica/Ecotech e acompanhado por técnicos do IBRAM – Instituto Brasília Ambiental.

Figura 3. 1. Imagem Rapideye de julho de 2015 (banda 3: 630 – 685 nm; banda 4: 690 – 730 nm; e banda 5: 760 – 850 nm) e representação das fitofisionomias presentes na Estação Ecológica de Águas Emendadas.



Fonte: Adaptado de Geo Lógica/Ecotech (2009).

A precipitação média na ESEC-AE é de 1.552 mm/ano, com mais de 95% do volume da precipitação concentrado de outubro a abril, caracterizando a forte sazonalidade das chuvas. A temperatura média anual é em torno 21 °C, com pouca variação térmica entre os meses de verão e inverno (MAIA; BAPTISTA, 2008). A Figura 3.2 mostra a precipitação dos dois últimos anos (2014 e 2015) e a média de precipitação desde 2008, ano em que foi instalada a estação meteorológica Águas Emendadas do INMET (A045), localizada dentro da ESEC-AE. Os anos de 2014 e 2015 apresentaram precipitações semelhantes, principalmente entre os meses de janeiro a outubro.

Figura 3. 2. Precipitação acumulada mensal (mm) do ano de 2014, 2015 e média desde 2008. Dados da estação meteorológica automática Águas Emendadas (A045), fornecidos pelo Instituto Nacional de Meteorologia (INMET). A área sombreada representa o período seco ao longo do ano.



O relevo abrange aproximadamente as altitudes entre 1.000 e 1.200 metros, típicas na região do Distrito Federal (MAIA; BAPTISTA, 2008). As principais classes de solos descritas em Águas Emendadas são: Latossolos Vermelhos, Latossolos Vermelho-Amarelo, Gleissolos Háplicos, Cambissolo Háplicos e Neossolos Quartzarênicos. A Figura 3.3 apresenta o mapa de solo correspondente ao levantamento pedológico de reconhecimento em escala 1:100.000, realizado pelo Serviço Nacional de Levantamento de Solos (EMBRAPA, 1978).



Figura 3. 3. Mapa de solos da Estação Ecológica de Águas Emendadas, segundo Embrapa (1978).

Fonte: Lacerda (2008).

Segundo Rocha (2008), os principais problemas enfrentados na região estão relacionados com: 1) a retirada da cobertura vegetal nos entornos da estação; 2) questões fundiárias regionais, com ocupação irregular do entorno por chácaras e loteamento, cujas atividades são responsáveis por sérios problemas como reflorestamento com Pinus e Eucalipto, plantio de culturas anuais (soja, milho, arroz e outros) com uso de agrotóxicos e fertilizantes, promovendo a contaminação dos recursos hídricos e o assoreamento da Lagoa Bonita e dos ribeirões; 3) captação de água para abastecimento público, atividade incompatível com uma unidade de conservação de proteção integral, promovendo a presença de espécies exóticas e drenagens de veredas. Apesar de todos os problemas enfrentados desde sua implantação, a ESEC-AE vem ganhando espaço na comunidade científica, com pesquisas em diferentes áreas do conhecimento, cumprindo assim os objetivos que justificaram sua criação (FERREIRA, 2006; FERREIRA et al., 2011; LACERDA; BARBOSA, 2012; OLIVEIRA FILHO; RATTER, 2002; SILVA-JÚNIOR; FELFILI, 1996).

## 4. METODOLOGIA DE TRABALHO

A Figura 4.1 apresenta a sequência de etapas metodológicas adotadas na execução do trabalho. Estas etapas serão descritas nas seções subsequentes.

Figura 4. 1. Fluxograma indicando as etapas desenvolvidas no trabalho. AGB refere-se a biomassa acima do solo; PLSR refere-se a regressão por mínimos quadrados parciais; MDA refere-se a análise discriminante múltipla; e IVs refere-se aos índices de vegetação.



## 4.1. Seleção da área de estudo

A Estação Ecológica de Águas Emendadas (ESEC-AE) foi selecionada como área de estudo por representar uma das áreas protegidas de maior biodiversidade dos Cerrados brasileiros, e por conter variadas fitofisionomias do Cerrado, representativas do domínio *core* desse bioma. Sendo assim, muitos dos trabalhos científicos desenvolvidos na Estação alcançaram *status* de relevância na comunidade científica (MAIA, 2008).

## 4.2. Aquisição e tratamento dos dados de campo

#### 4.2.1. Inventário florestal

A campanha de campo foi realizada em julho de 2015, mês correspondente ao período seco. Foram amostradas 45 parcelas de 20 m x 50 m, dimensão adotada por Felfili et al. (2005a), totalizando 4,5 ha. Para as parcelas de cerrado denso, cerrado típico, cerrado ralo e campo cerrado, foram medidos todos os indivíduos arbóreo-arbustivo vivos com diâmetro com casca (tomado a 30 cm da base do solo - Db) igual ou superior a 5 cm. Todos os indivíduos incluídos na medição foram identificados botanicamente (família e espécie) por um para-botânico, especialista da Embrapa Cerrados. Os nomes científicos de cada espécie bem como das famílias botânicas foram conferidos por meio da Lista de Espécies da Flora do Brasil (http://floradobrasil.jbrj.gov.br/) e da base de dados do *Missouri Botanical Garden* (http://www.tropicos.org). Alguns poucos indivíduos ainda tiveram exsicatas coletadas para a identificação no herbário da EMBRAPA-Cerrados.

A altura total (Ht) dos indivíduos inventariados foi medida com auxílio de uma régua com altura conhecida. Nas fitofisionomias campo sujo e campo limpo foram alocadas 5 subparcelas de 1 m<sup>2</sup> distribuídas sistematicamente de 10 em 10 m dentro da parcela de 20 x 50 m, conforme recomendado por Felfili et al. (2005a), onde todo material herbáceo foi coletado, ensacado e pesado ainda em campo com uma balança de pequeno porte. Depois, no laboratório da EMBRAPA-Cerrados, as amostras de cada subparcela foram preparadas, pesadas e posteriormente levadas para secagem em estufa de circulação forçada de ar, a uma temperatura de aproximadamente 65°C (Figura 4.2) durante 48 horas, ou até a estabilização do seu peso de matéria seca, procedimento esse recomendado por Ribeiro et al. (2011).

Figura 4. 2. Amostras de campo sendo coletadas, pesadas e secadas em estufa cedida pela Embrapa Cerrados em Planaltina-DF. (a) alocação das subparcelas dentro da parcela, (b) subparcela de 1 x 1 m, (c) pesagem das amostras e (d) estufa de circulação forçada de ar, onde as amostras foram secas.



O número de parcelas alocadas em cada fitofisionomia foi definido conforme distribuição das fitofisionomias na área e facilidade de acesso (Tabela 4.1).

Fitofisionomia	Sigla	Parcela ID	N°	Área total (ha)
cerrado denso	CD	P6, P7, P13, P14, P16, P17, P20	7	0,7
cerrado típico	С	P2, P3, P4, P5, P8, P9, P10, P11, P12, P15, P18, P19, P21, P23	14	1,4
cerrado ralo	CR	P1, P22, P24, P26, P27, P28	6	0,6
campo cerrado	CaC	P25, P29, P30, P31, P32, P33	6	0,6
campo sujo	CaS	P40, P42	2	0,2
campo limpo	CaL	P34, P35, P36, P37, P38, P39, P41, P43, P44, P45	10	1,0

Tabela 4. 1. Identificação das parcelas amostradas em cada fitofisionomia.

Todas as parcelas tiveram posicionamento registrado por meio da utilização de GPS de navegação. O posicionamento dos indivíduos arbóreo-arbustivos de algumas parcelas foi feito por meio do registro de coordenadas cartesianas X e Y. Além das parcelas inventariadas, representativas de cada fitofisionomia, foram coletados 107 pontos de observação aleatoriamente distribuídos dentro da ESEC-AE, abrangendo não apenas as fitofisionomias analisadas neste estudo, mas também a ocorrência de veredas, mata de galeria, regeneração de vegetação, presença de queimadas, ramais e vias de acesso para controle, dentre outras características.

## 4.2.2. Caracterização florística e estrutural das fitofisionomias

Para a caracterização florística e estrutural, apenas as fitofisionomias compostas por indivíduos arbóreo-arbustivos foram consideradas nesta análise: cerrado denso, cerrado típico, cerrado ralo e campo cerrado.

A suficiência amostral do inventário foi avaliada com base na curva espécie-área. Esta curva pode ser vista como um processo de interpolação a partir da riqueza de espécies agrupadas com o incremento de amostras para a riqueza esperada de um subconjunto daquela amostra (COLWELL et al., 2004). A curva é crescente até atingir o ponto de estabilização, ou seja, o incremento de novas espécies é baixo mesmo com o aumento de amostras (SCHILLING; BATISTA, 2008).

A composição florística e a diversidade de espécies foram analisadas por meio do índice de Shannon-Weaver (H') (Equação 4.1) e da equabilidade de Pielou (J) (Equação 4.2):

$$H' = -\sum_{i=1}^{s} [p_i \ln (p_i)], \ com \ p_i = \frac{n_i}{N}$$
(4.1)

$$J = \frac{H'}{\ln(S)} \tag{4.2}$$

onde:  $n_i$  é o número de indivíduos da espécie *i*, *N* é o número total de indivíduos e *S* é o número total de espécies.

O índice de Shannon-Weaver é diretamente proporcional à diversidade florística da área amostrada. Esse índice é calculado com base na relação entre o número de indivíduos por espécie e o número total de indivíduos amostrados. Quanto maior for o valor de H', maior será a diversidade florística do conjunto amostral. O índice combina as componentes riqueza e equabilidade. A equabilidade de Pielou expressa a maneira pela qual o número de indivíduos está distribuído entre as diferentes espécies. O índice mede a uniformidade da comunidade analisada, indicando se as diferentes espécies possuem valores de abundância semelhantes ou divergentes. O valor deste índice varia de 0 a 1, onde 1 representa a máxima uniformidade, ou seja, todas as espécies são igualmente abundantes (MAGURRAN, 1988).

A análise da estrutura das fitofisionomias seguiu os parâmetros descritos por Mueller-Dombois e Ellenberg (1974). Área basal (AB) refere-se ao grau de ocupação do terreno pelos fustes das árvores, sendo a soma das áreas transversais dos indivíduos obtidos a partir do DAP ou Db por unidade de área (m<sup>2</sup>.ha<sup>-1</sup>); densidade absoluta (DA) indica o número de indivíduos de uma determinada espécie por unidade de área; densidade relativa (DR) refere-se ao número de indivíduos de uma determinada espécie em relação ao total de indivíduos de todas as espécies identificadas no levantamento; frequência absoluta (FA) expressa a porcentagem de parcelas em que cada espécie ocorre; frequência relativa (FR) é a porcentagem de ocorrência de uma espécie em relação à soma das frequências absolutas de todas as espécies; dominância absoluta (DoA) é a soma das áreas basais dos indivíduos pertencentes a uma espécie, por unidade de área; dominância relativa (DoR) indica a porcentagem da área basal de cada espécie que compõe a área basal total de todos os indivíduos de todas as espécies, por unidade de área; índice de valor de importância (IVI) é a soma dos valores relativos de densidade, dominância e frequência relativa de cada espécie, permitindo uma visão mais ampla de sua importância no total do povoamento.

Adicionalmente foram analisados gráficos de distribuição diamétrica, com intervalo de 4 cm para os parâmetros altura total, densidade, área basal e biomassa. Comparações entre parâmetros médios das fitofisionomias foram feitas por meio da análise de variância (ANOVA,  $\alpha$ =0,05) e do teste Tukey. As variáveis foram verificadas quanto à

normalidade pelo teste Shapiro-Wilk (SHAPIRO; WILK, 1965) e homocedasticidade pelo teste de Bartlett (SNEDECOR; COCHRAN, 1983).

Nas parcelas de CD, C, CR e CaC, a estimativa de biomassa seca acima do solo de cada indivíduo lenhoso vivo foi obtida por meio da equação alométrica proposta por Rezende et al. (2006) para o cerrado *sensu stricto* em Brasília- DF (Equação 4.3):

$$AGB = -0,4913 + 0,0291 * Db^2 * Ht$$
(4.3)

onde *AGB* corresponde a biomassa individual acima do solo (kg); *Db* corresponde ao diâmetro medido a 30 cm da base do solo (cm) e *Ht* corresponde a altura total (m).

A AGB foi considerada como a soma das biomassas individuais, extrapoladas para tonelada por hectare.

Nas parcelas de campo sujo e campo limpo, os cálculos de biomassa foram efetuados seguindo o método da proporcionalidade proposto por Ribeiro et al. (2011) (Equação 4.4):

$$Ms(c) = \frac{Mu(c) * Ms(a)}{Mu(a)}$$
(4.4)

onde Ms(c) corresponde a massa de matéria seca total no campo em kg; Ms(a) corresponde a massa de matéria seca das amostras em kg, após secagem em estufa; Mu(a) corresponde a massa de matéria úmida das amostras em kg; e Mu(c) corresponde a massa de matéria úmida total no campo em kg.

#### 4.3. Seleção e pré-processamento das imagens Hyperion

Foram utilizadas seis imagens do sensor Hyperion, correspondentes aos meses de março a agosto de 2014. Não foi possível o uso das imagens de 2015, ano do desenvolvimento deste estudo, pela alta cobertura de nuvens no período chuvoso e ausência de imagens concomitantes ao período seco das atividades de campo em julho de 2015. No entanto, os anos de 2014 e 2015 apresentaram precipitações semelhantes, principalmente nos meses analisados (Figura 3.2). Assume-se então um comportamento fenológico da vegetação aproximadamente similar entre os dois anos, sem possíveis anomalias de precipitação que pudessem prejudicar a interpretação dos resultados.

A sequência de imagens foi selecionada com o intuito de caracterizar a sazonalidade da vegetação no período chuvoso (março e abril) e seco (maio, junho, julho e agosto). As imagens foram obtidas a partir da plataforma *Earth Explorer* da USGS/NASA e suas respectivas informações podem ser observadas na Tabela 4.2 e Figura 4.3.

Informações	Março	Abril	Maio	Junho	Julho	Agosto
Data de aquisição	20/03/2014	13/04/2014	23/05/2014	16/06/2014	10/07/2014	03/08/2014
Azimute solar	73.5	60.9	48.4	47.0	49.3	54.6
Elevação solar	45.8	43.2	36.8	34.0	33.3	35.4
Ângulo de apontamento	+10.3	+13.9	+14.5	+13.5	+11.7	+8.6

Tabela 4. 2. Informações sobre as seis imagens Hyperion/EO-1 utilizadas neste estudo.





Os pré-processamentos e os processamentos realizados nas imagens foram feitos no aplicativo ENVI 5.0 (EXELIS, 2013). As imagens Hyperion/EO-1 apresentam pixels ruidosos que formam linhas ou "faixas escuras", perpendiculares à linha de varredura, conhecidas como stripes, que compreendem as informações perdidas durante a aquisição dos dados. Os stripes foram substituídos automaticamente pela média de seus vizinhos na direção horizontal por meio de um algoritmo. Destaca-se que esse procedimento não agrega novas informações nas imagens; melhora apenas seu aspecto visual (SOUZA et al., 2010). Os dados de radiância foram convertidos para reflectância de superfície utilizando o Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes (FLAASH), o qual é baseado no modelo de transferência radiativa MODTRAN-4 (Moderate Resolution Transmittance Code) (FELDE et al., 2003). O principal objetivo do FLAASH é a remoção dos efeitos de espalhamento e absorção da radiação devido aos constituintes atmosféricos. O modelo atmosférico utilizado foi o tropical/ rural, com visibilidade variando de 35 a 70 km, dependendo de cada imagem. A banda de absorção de vapor d'água utilizada para a estimativa desse constituinte atmosférico foi a de 1135 nm. Um algoritmo para a remoção de ruído e feições espúrias decorrentes da correção atmosférica foi aplicado sobre os dados. Bandas posicionadas em torno de 1400 nm e 1900 nm foram excluídas da análise subsequente de dados devido à forte absorção atmosférica pelo vapor de água, que limita o uso destes dados mesmo após a correção atmosférica (GALVÃO et al., 2005). No total, 146 bandas espectrais foram utilizadas nas análises subsequentes.

A correção geométrica das imagens Hyperion L1R foi realizada utilizando-se pontos de controle sobre feições correspondentes entre as imagens Hyperion e uma imagem TM/Landsat 5 ortorretificada. Para a transformação foi usado um polinômio do primeiro grau, adotando-se o sistema de projeção UTM zona 23S, datum WGS-84. Após o georreferenciamento, foi avaliado o resíduo em unidades de pixel, seguido pela reamostragem dos pixels da cena Hyperion pelo método de vizinho mais próximo.

## 4.4. Geração de atributos hiperespectrais

Atributos hiperespectrais visam caracterizar e representar a estrutura e fisiologia da vegetação, assim como a bioquímica e estrutura do dossel (GALVÃO et al., 2013). Para caracterizar espectralmente as fitofisionomias do cerrado, foram considerados os

seguintes atributos: 1) reflectâncias de bandas; 2) índices de vegetação; 3) razões de bandas; 4) parâmetros de bandas de absorção. Para caracterizar as reflectâncias foram utilizadas as 146 bandas resultantes do pré-processamento aplicado nas imagens Hyperion.

Foram calculados 22 índices de vegetação de bandas estreitas (ROBERTS et al., 2011). As equações matemáticas e as referências dos IVs utilizados estão descritas na Tabela 4.3.

Indices de Vegetação	Fórmula	Referência
	Estrutura	
EVI	$2.5\times((\rho 864-\rho 660)/(\rho 864+6\times\rho 660-7.5\times\rho 487+1))$	Huete et al. (2002)
NDVI	(p864 - p660)/(p864 + p660)	Rouse et al. (1973)
VARI	$(\rho 559 - \rho 660)/(\rho 559 + \rho 660 - \rho 487)$	Gitelson et al. (2002a)
VIg	(p559 – p660)/(p559 + p660)	Gitelson et al. (2002a)
	Bioquímica	
ARI	(1/ p559) - (1/ p721)	Gitelson et al. (2001)
CAI	100*[0.5*( p2032+ p2213)- p2102]	Daughtry (2001)
CRI1	(1/ p510) - (1/ p550)	Gitelson et al. (2002b)
LWVI2	$(\rho 1094 - \rho 1205)/(\rho 1094 + \rho 1205)$	Galvão et al. (2005)
MCARI	$[(\rho 701 - \rho 671) - 0.2*(\rho 701 - \rho 549)]*(\rho 701 / \rho 671)$	Daughtry et al. (2000)
MSI	(p1598)/ (p823)	Hunt e Rock (1989)
NDII	$(\rho 823 - \rho 1649)/(\rho 823 + \rho 1649)$	Hunt e Rock (1989)
NDLI	$[\log(1/\rho 1754) - \log(1/\rho 1680)] / [\log(1/\rho 1754) + \log(1/\rho 1680)]$	Serrano et al. (2002)
NDWI	$(\rho 854 - \rho 1245)/(\rho 854 + \rho 1245)$	Gao (1996)
PSRI	(p681 – p498)/p752	Merzlyak et al. (1999)
PSSR	Ρ803/ρ671	Blackburn (1998)
SIPI	$(\rho 803 - \rho 467)/(\rho 803 + \rho 681)$	Penuelas et al. (1995)
WBI	ρ 905/ρ972	Penuelas et al. (1997)
	Fisiologia	
PRI	$(\rho 529 - \rho 569)/(\rho 529 + \rho 569)$	Gamon et al. (1997)
RENDVI	$(\rho 752 - \rho 701)/(\rho 752 + \rho 701)$	Gitelson et al. (1996)
REPI	L( máxima primeira derivada no intervalo 690-740 nm)	Horler et al (1983)
RVSI	[(p712 + p752)/2] - p732	Merton e Huntington (1999)
VOG	ρ742/ρ722	Vogelmann et al. (1993)

Tabela 4. 3. Índices de vegetação utilizados com suas respectivas fórmulas e referências.

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

Segundo Roberts et al. (2011), os índices de vegetação (IVs) mais relacionados com a estrutura do dossel são: Enhanced Vegetation Index (EVI); Normalized Difference Vegetation Index (NDVI); Visible Atmospherically Resistant Index (VARI) e o Visible Green Index (VIg). Os IVs mais associados com a bioquímica são: Anthocyanin Reflectance Index (ARI); Cellulose Absorption Index (CAI); Carotenoid Reflectance Index 1 (CRI1); Leaf Water Vegetation Index 2 (LWVI2); Modified Chlorophyll Absorption Ratio Index (MCARI); Moisture Stress Index (MSI); Normalized Difference Infrared Index (NDII); Normalized Difference Lignin Index (NDLI); Normalized Difference Stress Index (NDLI); Normalized Difference Infrared Index (NDWI); Plant Senescence Reflectance Index (PSRI); Pigment Specific Simple Ratio (PSSR); Structure Insensitive Pigment Index (SIPI) e Water Band Index (WBI). Finalmente, aqueles que melhor expressam a fisiologia da vegetação são: Photochemical Reflectance Index (PRI); Red Edge Normalized Difference Vegetation Index (RENDVI); Red Edge Position Index (REPI); Red-Edge Vegetation Stress Index (RVSI) e Vogelmann Red Edge Index (VOG).

Para o cálculo das razões de bandas foram determinadas todas as possíveis razões de bandas simples (numerador/denominador) derivadas das 146 bandas do sensor Hyperion, resultando em 10585 razões. Como vários índices de vegetação são compostos por razões de bandas, essa etapa é uma forma indireta de considerar na análise outros índices além dos já relacionados (SOUZA et al., 2010).

Os parâmetros de banda de absorção foram calculados pelo processo de remoção do contínuo espectral (CLARK; ROUSH, 1984). Esse método permite a filtragem das bandas de absorção de interesse dos espectros, removendo o sinal de fundo (KOKALY; SKIDMORE, 2015). A remoção do contínuo serviu como base para calcular os parâmetros que descrevem as características das bandas de absorção, tais como a profundidade, largura (largura à meia altura - *full width at half maximum* – FWHM), área e assimetria da banda de absorção em análise. Variações destes parâmetros descrevem, em termos simples, a variação nas propriedades de absorção (KOKALY, 2011). O espectro do contínuo removido (R') é calculado dividindo os valores de reflectância original dentro da feição espectral, pelo valor de uma linha contínua correspondente (Figura 4.4), estabelecida entre os dois pontos finais (esquerdo e direito) da feição (CLARK; ROUSH, 1984).

Figura 4. 4. Representação do espectro de vegetação verde; (a) limites do contínuo sobre a banda de absorção de clorofila (680 nm), (b) parâmetros da banda de absorção após remoção do contínuo.



Fonte: Sanches et al. (2014).

As imagens então foram processadas utilizando o *software* USGS PRISM (*Processing Routines in IDL for Spectroscopic Measurements*). PRISM é um *software* para análise espectroscópica escrito em IDL (*Interactive Data Language*) como um *plug-in* para o *software* ENVI. As características calculadas foram profundidade, largura, área e assimetria para as bandas de absorção posicionadas em 680 nm (clorofila); 980 nm e 1200 nm (água nas folhas); 1700 nm, 2100 nm e 2300 nm (lignina-celulose) (GALVÃO et al., 2005).

Os atributos foram gerados para toda a imagem, pixel-a-pixel, tendo seus valores subsequentemente extraídos para as etapas de caracterização e discriminação espectro-sazonal das fitofisionomias de cerrado e de modelagem da biomassa.

# 4.5. Caracterização e discriminação espectro-sazonal das fitofisionomias de Cerrado

A caracterização foi realizada com base na seleção de aproximadamente 700 pixels para cada imagem e conjunto de fitofisionomias, mantendo-se sua posição geográfica fixa entre imagens. A distribuição dos pixels teve como base as observações de campo e a representação baseada no mapa do plano de manejo da ESEC-AE, resultando em aproximadamente 100 pixels para cada fitofisionomia (cerrado denso, cerrado típico, cerrado ralo, campo cerrado, campo sujo, campo limpo e mata de galeria). Em alguns poucos casos, pixels com valores espúrios foram eliminados da análise. Pixels representativos da mata de galeria foram incluídos nas etapas de caracterização e

discriminação. A caracterização espectral foi realizada inicialmente com todas as imagens para representar a sazonalidade dos índices de vegetação nas diferentes fitofisionomias. Posteriormente, as análises se limitaram ao período chuvoso (imagem de março de 2014) e ao período seco (imagem de agosto de 2014), destacando características específicas das fitofisionomias nos meses que mais caracterizam os dois períodos analisados. Para caracterizar esses dois períodos foram utilizados os valores de reflectância, índices de vegetação e parâmetros de bandas de absorção na construção de gráficos de espalhamento. Comparações entre valores médios de reflectância em 660 nm, 864 nm e 1648 nm das sete fitofisionomias foram feitas por meio da análise de variância (ANOVA,  $\alpha$ =0,05) e do teste Tukey. Estes comprimentos de onda representam respectivamente as regiões do vermelho, IVP e SWIR 1. Valores médios dos 22 IVs, e seus respectivos desvios-padrões foram analisados pela porcentagem de mudança entre o período chuvoso e seco. O teste Shapiro-Wilk (SHAPIRO; WILK, 1965) foi aplicado para verificar a normalidade na distribuição dos atributos (GALVÃO et al., 2011).

Para a discriminação das fitofisionomias foi utilizada a técnica de análise discriminante múltipla (MDA - Multiple discriminant analysis). Esta técnica foi aplicada separadamente em cada grupo de atributos (reflectância, índices de vegetação, parâmetros de bandas de absorção, e todos os atributos), e em cada período (chuvoso e seco). Para selecionar um subconjunto de atributos e produzir uma função discriminante adequada foi utilizado o procedimento passo-a-passo, que procura maximizar a Distância de Mahalanobis entre os grupos mais similares. Valores de probabilidade F foram usados como critério para a inclusão (0,01) e remoção (0,05) das variáveis. Escores discriminantes foram calculados e analisados em gráficos de espalhamento para cada conjunto de atributos, em cada período. Os pixels utilizados nesta etapa (aproximadamente 100 para cada fitofisionomia) foram divididos aleatoriamente em 50% para treinamento das funções discriminantes e 50% para validação do desempenho da classificação com MDA. Além da análise individual da separabilidade das fitofisionomias no período chuvoso e no período seco, os parâmetros acurácia global, índice Kappa e teste Z (Equação 4.5), sobre o índice Kappa, foram calculados (CONGALTON; MEAD, 1983):

$$Z = \frac{\hat{K}_1 - \hat{K}_2}{\sqrt{\hat{\sigma}_{K_1} + \hat{\sigma}_{K_2}}}$$
(4.5)

onde *K1* e *K2* são os índices kappa para as classificações do período chuvoso (1) e seco (2), e  $\hat{\sigma}_{K_1} e \hat{\sigma}_{K_2}$  são as variância kappa para as classificações 1 e 2.

Segundo Millán et al. (2014), em estudos sobre discriminação de estágios sucessionais em Mata Seca, características importantes são ressaltadas quando incluída a componente sazonal na análise do comportamento da vegetação. Durante a estação seca, mesmo com diferentes níveis de espécies caducifólias, os sensores capturam de forma mais eficiente as diferenças estruturais na vegetação, correspondentes à área basal, densidade de árvores e condições de sub-bosque observados através da abertura do dossel. Já na estação chuvosa, a resposta da vegetação pode se confundir pela maior interferência do dossel, mais vigor da vegetação nessa época, dispersando a radiação em várias direções, devido à orientação das folhas e sombras decorrentes, dentre outros fatores (MILLÁN et al., 2014). O comportamento sazonal da vegetação, como é verificado no Cerrado, resulta em uma gama de possibilidade de análises das diferentes características em cada período. Esta é a razão para que ambos os períodos fossem testados no presente estudo quanto à classificação das fitofisionomias por MDA.

## 4.6. Modelagem da AGB por PLSR

Os atributos hiperespectrais utilizados nessa etapa (reflectância das 146 bandas do Hyperion, 22 IVs, 10585 razões de bandas e 24 parâmetros das bandas de absorção posicionadas em 680, 980, 1200, 1700, 2100 e 2300 nm), foram extraídos de 45 pixels, correspondentes às parcelas amostradas em campo, gerados para imagem de julho de 2014 (Tabela 4.1). As fitofisionomias analisadas foram CD, C, CR, CaC, CaS e CaL.

A campanha de campo foi realizada em julho de 2015, porém, neste período, não houve aquisição de imagens Hyperion. A estratégia adotada para o desenvolvimento desta etapa foi a utilização da imagem Hyperion de julho de 2014 para modelar a biomassa de 2015. Para justificar essa estratégia, foi feita uma simulação das bandas espectrais do sensor RapidEye a partir da imagem Hyperion 2014, utilizando a função de resposta dos filtros. Essa simulação foi feita para ser comparada com a imagem RapidEye adquirida

em julho de 2015, concomitante à coleta de dados em campo. Para realizar essa comparação e justificar o uso de uma imagem com defasagem de tempo de um ano, foi calculado o NDVI para as duas imagens relacionando-os com a biomassa observada em campo. Visto que as relações foram similares entre os dados originais e simulados, decidiu-se pelo prosseguimento da análise.

Inicialmente foi realizada uma análise exploratória dos dados a fim de se conhecer a relação entre cada conjunto de variáveis independentes e a dependente, assim como a relação dentro de cada conjunto de variáveis X. Para isto, foram utilizados diagramas de espalhamento e matrizes de correlação.

Para avaliar a relação entre a biomassa viva/seca acima do solo e os atributos hiperespectrais foi empregada a regressão PLSR pelo método NIPALS (GELADI; KOWALSKI, 1986). Para isto, a análise do conteúdo de biomassa foi abordada de maneira geral, ou seja, o objetivo não foi o ajuste de um modelo para cada fitofisionomia, mas sim, a construção de um modelo que pudesse abranger toda a variabilidade de biomassa existente na área de estudo. Ao todo, foram ajustados cinco modelos, permanecendo única a variável dependente biomassa (Y) e variando o conjunto de variáveis independentes X (Tabela 4.4). As análises foram realizadas utilizando o *software* Unscrambler® X 10.2 (CAMO *Software Inc.*, Woodbridge, Noruega).

Tabela 4. 4. Descrição do número de variáveis independentes e dependente (AGB), assim como o número de amostras utilizadas.

Modelo	Nº de Variáveis independentes (X)	Nº de Variáveis Dependentes (Y)	Nº de amostras
Reflectância	146	1	45
Índices de Vegetação	22	1	45
Razões de banda	10585	1	45
Parâmetros de bandas de absorção	24	1	45
Geral	10777	1	45

Para compreender o comportamento de cada variável X em cada modelo ajustado, foi realizada análise dos escores e teste Hotelling T<sup>2</sup> (estatística multivariada homóloga ao teste t de *Student*), *Loadings*, Influência (*Outliers e Leverages*), e variância explicada e

residual de Y. As características e fórmulas de cada método de análise, utilizadas pelo *software* Unscrambler® X 10.2, estão descritas em Hubert e Vanden-Branden (2003) e CAMO (2013).

A validação dos modelos foi realizada por meio da validação cruzada, método utilizado por diferentes autores para verificar o poder preditivo dos modelos PLSR (CLEVERS et al., 2007; HANSEN; SCHJOERRING, 2003; LAURIN et al., 2014; MARABEL; ALVAREZ-TABOADA, 2013). No geral, os resultados dos modelos neste estudo foram avaliados em termos do número de fatores (PCs), do coeficiente de determinação (R<sup>2</sup>), e da raiz quadrada do erro quadrático médio (RMSE). Para considerar um modelo mais preciso do que outro, a redução do RMSE da validação cruzada deve ser em pelo menos 2% entre os modelos comparados. Esse mesmo critério foi utilizado para estabelecer o número ótimo de PCs em cada modelo, ou seja, o critério para adicionar um novo fator no modelo foi a redução do RMSE da validação cruzada em pelo menos 2% (KOOISTRA et al., 2004).

## 5. **RESULTADOS E DISCUSSÃO**

#### 5.1. Caracterização florística e estrutural das fitofisionomias

No total foram inventariadas 45 parcelas, das quais apenas 33 (3,3 ha) foram analisadas florística e estruturalmente para caracterizar as fitofisionomias arbóreo-arbustivas de Cerrado presentes na região. O padrão encontrado na curva espécie-área (Figura 5.1) mostra que os padrões que expressam a questão florística nessa localidade estudada estão em consonância com os registros dos Cerrados analisados por Felfili e Silva Júnior (2001). A partir de 4.000 m<sup>2</sup> de área amostrada, há significativa redução no número de novas espécies encontradas, sendo que na sexta parcela, cerca de 80% do total de espécies já haviam sido amostradas nas tipologias sob análise. Isso conduziu a percepção de que, a partir desse tamanho amostral, a inclusão de novas espécies ocorria numa taxa variável e decrescente de 2% a cada nova parcela, indicando o alcance da estabilização na curva. Isto demonstrou que a variabilidade florística estava convenientemente amostrada (ASSUNÇÃO; FELFILI, 2004).

Figura 5. 1. Curva espécie-área obtida por meio das parcelas amostrais inventariadas (n=33). Linhas pontilhadas representam o intervalo de confiança (α=0,05)



De maneira geral, nas 33 parcelas amostradas, o número total de indivíduos foi de 6.407 árvores, distribuídas em 34 famílias botânicas, 60 gêneros e 76 espécies.

Os valores de diversidade de Shannon (H') e equabilidade de Pielou (J), obtidos para cada fitofisionomia (Tabela 5.1), foram compatíveis com outros estudos desenvolvidos

em áreas de cerrado *sensu stricto*, com H' variando entre 3,04 a 3,73 (FELFILI et al., 1992; 1994; 2001). No entanto, os valores do índice de Shannon foram inferiores ao obtido por Felfili e Silva Jr. (1996) em estudo realizado no cerrado *sensu stricto* da ESEC-AE (H'=3,62).

Os valores dos índices variaram com relação a composição florística de cada estrato, sendo que o C apresentou a maior riqueza e diversidade de espécies com relação aos outros estratos, diferentemente do campo cerrado que apresentou os menores valores para os mesmos índices. Os valores encontrados para a equabilidade de Pielou (J) foram similares, demonstrando a baixa uniformidade entre as espécies encontradas em cada tipologia.

Tabela 5. 1. Riqueza de espécies, índice de Shanon (H') e equabilidade de Pielou (J) de cada fitofisionomia amostrada na ESEC-AE.

Fitofisionomias	Riqueza (esp.)	Shannon (H')	Pielou (J)
CD	65	3,28	0,79
С	69	3,35	0,79
CR	58	3,30	0,81
CaC	55	3,14	0,78

Para uma análise florística mais detalhada, a Tabela 5.2 mostra a relação dos parâmetros fitossociológicos das dez espécies de maior índice de valor de importância (IVI) para cada fitofisionomia. No geral, mesmo que a composição florística apresente espécies sendo compartilhadas entre as tipologias, foi possível verificar a influência de cada espécie, em termos de densidade, frequência e dominância, nas diferentes densidades de Cerrado amostradas. As espécies *Miconia sp.* (miconia – Melastomastaceae), *Kielmeyera coriacea* Mart. (pau-santo – Clusiaceae) e *Sclerolobium paniculatum* Vogel (carvoeiro – Fabaceae) foram consideradas como tendo maior importância nas áreas de cerrado denso (CD) e cerrado típico (C). Juntas, elas contribuíram com 34% da densidade e 33% da dominância do CD e 29% da densidade e 32% da dominância do C.

Tabela 5. 2. Parâmetros fitossociológicos calculados para as dez espécies de maior IVI, ordenadas por fitofisionomia e em ordem decrescente. As abreviações correspondem a: densidade absoluta (DA), densidade relativa (DR), dominância absoluta (DoA), dominância relativa (DoR), frequência absoluta (FA), frequência relativa (FR) e Índice de Valor de Importância percentual (IVI).

FITOFICIONOMIAS	ES DÉCUES	DA	DR	FA	FR	DoA	DoR	IVI
FITUFISIONUMIAS	ESPECIES	(ind.ha <sup>-1</sup> )	(%)	(%)	(%)	(m <sup>2</sup> .ha <sup>-1</sup> )	(%)	(%)
	Miconia sp.	434	18.0	85.7	2.2	3.9	17.6	12.6
	Kielmeyera coriacea Mart.	293	12.1	100.0	2.6	1.3	5.9	6.9
	Sclerolobium paniculatum Vogel	86	3.6	100.0	2.6	2.2	9.9	5.3
	Qualea parviflora Mart.	154	6.4	100.0	2.6	1.5	7.0	5.3
CD	Qualea grandiflora Mart.	110	4.6	100.0	2.6	1.6	7.3	4.8
CD	Davilla elliptica A. StHil.	149	6.2	85.7	2.2	0.8	3.6	4.0
	Caryocar brasiliense A.StHil.	70	2.9	100.0	2.6	1.4	6.2	3.9
	Pouteria ramiflora (Mart.) Radlk	96	4.0	100.0	2.6	1.0	4.5	3.7
	Ouratea hexasperma (A.StHil.) Baill.	97	4.0	100.0	2.6	0.8	3.4	3.3
	Bowdichia virgilioides Kunth	50	2.1	100.0	2.6	0.7	3.1	2.6
	Miconia sp.	234	10.8	92.9	2.7	2.0	11.9	8.5
	Kielmeyera coriacea Mart.	300	13.8	100.0	3.0	1.4	8.4	8.4
	Sclerolobium paniculatum Vogel	99	4.5	100.0	3.0	2.0	12.1	6.5
	Davilla elliptica A. StHil.	196	9.1	100.0	3.0	1.0	6.0	6.0
C	Qualea parviflora Mart.	102	4.7	92.9	2.7	1.2	7.1	4.9
t	Ouratea hexasperma (A.StHil.) Baill.	136	6.3	100.0	3.0	0.8	4.7	4.6
	Pouteria ramiflora (Mart.) Radlk	106	4.9	92.9	2.7	1.0	6.3	4.6
	Qualea grandiflora Mart.	64	3.0	92.9	2.7	0.8	4.8	3.5
	Caryocar brasiliense A.StHil.	47	2.2	85.7	2.5	0.8	4.6	3.1
	Roupala montana Aubl.	71	3.3	78.6	2.3	0.5	2.9	2.8
	Kielmeyera coriacea Mart.	357	21.8	100.0	3.2	1.6	13.8	12.9
	Miconia sp.	145	8.9	83.3	2.7	1.5	13.0	8.2
	Qualea parviflora Mart.	55	3.4	83.3	2.7	1.1	9.4	5.2
	Davilla elliptica A. StHil.	88	5.4	100.0	3.2	0.4	3.6	4.1
CP	Ouratea hexasperma (A.StHil.) Baill.	73	4.5	100.0	3.2	0.5	4.2	4.0
CK	Dalbergia miscolobium Benth.	77	4.7	83.3	2.7	0.5	4.3	3.9
	Annona crassiflora Mart.	43	2.7	100.0	3.2	0.4	3.3	3.1
	Caryocar brasiliense A.StHil.	38	2.3	66.7	2.2	0.5	4.5	3.0
	Sclerolobium paniculatum Vogel	27	1.6	83.3	2.7	0.5	4.2	2.8
	Stryphnodendron adstringens (Mart.) Coville	42	2.6	100.0	3.2	0.3	2.6	2.8
	Kielmeyera coriacea Mart.	290	25.0	100.0	4.1	1.1	13.4	14.2
	Davilla elliptica A. StHil.	105	9.0	83.3	3.4	0.6	7.2	6.5
	Sclerolobium paniculatum Vogel	47	4.0	66.7	2.7	1.0	12.1	6.3
	Eugenia dysenterica DC.	72	6.2	50.0	2.0	0.6	6.7	5.0
CaC	Stryphnodendron adstringens (Mart.) Coville	58	5.0	66.7	2.7	0.6	6.8	4.8
CaC	Ouratea hexasperma (A.StHil.) Baill.	57	4.9	66.7	2.7	0.2	2.5	3.4
	Piptocarpha rotundifolia (Less.) Baker	30	2.6	66.7	2.7	0.4	4.7	3.3
	Qualea parviflora Mart.	20	1.7	83.3	3.4	0.3	3.6	2.9
	Qualea grandiflora Mart.	25	2.2	66.7	2.7	0.3	3.6	2.8
	Styrax ferrugineus Nees & Mart.	28	2.4	66.7	2.7	0.2	2.4	2.5

Nas áreas de CR e CaC, a espécie *Kielmeyera coriacea* Mart se destacou, contribuindo com 22% da densidade de indivíduos do CR e 25% do CaC. As espécies *Dalbergia miscolobium* Benth. (jacarandá - Fabaceae) e *Annona crassiflora* Mart. (araticum - Annonaceae) foram encontradas em todas as tipologias, mas se destacaram entre as outras espécies apenas nas parcelas de CR. *Eugenia dysenterica* DC. (cagaita – Myrtaceae), *Piptocarpha rotundifolia* (Less.) Baker (vassourão-do-cerrado – Compositae) e *Styrax ferrugineus* Nees e Mart. (laranjinha – Styracaceae) se destacaram no CaC. *Kielmeyera coriacea* Mart foi a única espécie com 100% de ocorrência em todas as parcelas amostradas.

Cada fitofisionomia apresentou características particulares em termos qualitativos, formando um gradiente de vegetação já descrito por Ribeiro e Walter (1998). Cerrado denso (CD) e cerrado típico (C) possuem, sob ponto de vista estrutural, um gradiente no percentual de cobertura de copas dependente dos indivíduos arbóreo-arbustivos que compõe essas unidades citadas, chegando aos dosséis mais abertos nas classes de cerrado ralo (CR) e campo cerrado (CaC), cuja formação do substrato tem maior desenvolvimento do estrato graminóide (Figura 5.2). Nesse caso, com maior conteúdo de material não fotossinteticamente ativo no decorrer do período seco, há variação da massa graminóide em decorrência das ações de queimada passadas. Já o campo sujo (CaS) e campo limpo (CaL), formações abertas com no máximo 5% de cobertura arbórea-arbustiva esparsa (RIBEIRO; WALTER, 1998), mostraram predomínio de vegetação herbácea, muitas vezes em tufos graminóides, constatando-se, em algumas parcelas, um maior percentual de exposição de solo, como observado no decorrer do inventário realizado no período seco.

Figura 5. 2. Aspecto visual das fitofisionomias amostradas na Estação Ecológica de Águas Emendadas (ESEC-AE): (a) cerrado denso, (b) cerrado típico, (c) cerrado ralo, (d) campo cerrado, (e) campo sujo, (f) campo limpo.



Na Tabela 5.3 estão listados os valores médios dos parâmetros amostrados e estimados nas fitofisionomias CD, C, CR e CaC. Para CaL e CaS, apenas a biomassa foi calculada, conforme metodologia recomendada por Ribeiro et al. (2011) e descrita anteriormente.

Tabela 5. 3. Valores médios e desvio padrão dos parâmetros biofísicos de cada fitofisionomia amostrada na ESEC-AE.

<b>ΒΑΒÂΜΕΤΒΟ</b> Ω	FITOFISIONOMIAS						
rakawietkos	CD	С	CR	CaC	CaS	CaL	
Número de parcelas	7	14	6	6	2	10	
Biomassa (t.ha <sup>-1</sup> )	$34.46\pm2.7$	$26.56\pm 6.93$	$14.08\pm5.93$	$9.73 \pm 3.38$	$5.83 \pm 1.35$	$3.98\pm0.70$	
Altura média (m)	3.00	2.66	2.51	2.32	-	-	
Área basal (m².ha <sup>-1</sup> )	$22.03 \pm 1.54$	$16.52\pm2.16$	$11.72\pm4.68$	$8.27 \pm 1.60$	-	-	
Densidade (ind.ha <sup>-1</sup> )	$2415\pm388$	$2171\pm475$	$1635\pm394$	$1162\pm273$	-	-	

As distribuições diamétricas dos indivíduos inventariados nas fitofisionomias CD, C, CR e CaC, apresentaram o formato J-invertido, com maior densidade de indivíduos de menores diâmetros (Db) (Figura 5.3). Este tipo de distribuição indica que a comunidade se encontra em equilíbrio, com propriedades autorregenerativas, caso não seja intensamente perturbada (ASSUNÇÃO; FELFILI, 2004).

Nas parcelas de CaC, cerca de 96% de seus indivíduos se concentram nas três primeiras classes de diâmetro (até 17 cm), com altura média variando entre 1,8 a 4,3 m nesse

intervalo. No CR, também há o predomínio de indivíduos nas três primeiras classes diamétricas observando-se, contudo, certa frequência de indivíduos de maior porte, inclusive com ocorrência de 0,2% de indivíduos na classe de 37 a 41 cm e altura média de 6,7 m. C apresentou indivíduos melhor distribuídos ao longo das classes de diâmetro, com cerca de 87% dos indivíduos com até 13 cm de Db. Os 13% restantes de árvores estão distribuídas até 45 cm de Db. Nesta tipologia, verificou-se um intervalo sem a presença de indivíduos de 37 a 41 cm, mas com ocorrência de indivíduos emergentes no intervalo de 41 e 45 cm. CD apresentou distribuição similar à de C, com indivíduos melhor distribuídos nas classes de Db. É Importante destacar que o atributo dendrométrico de altura média teve seu valor abruptamente diminuído em algumas poucas amostras nessas unidades fitofisionômicas, razão da presença de alguns indivíduos de grande porte quebrados, ou mesmo caídos, o que influenciou no decréscimo do padrão esperado dos valores médios das alturas, principalmente nas fitofisionomias CD e C.

Figura 5. 3. Distribuição diamétrica dos indivíduos arbóreo-arbustivos por fitofisionomia e suas respectivas alturas médias.



Os parâmetros densidade de indivíduos, altura total (HT), diâmetro (Db), área basal (AB) e biomassa (AGB) atenderam aos requisitos da ANOVA, verificados por meio do teste de normalidade (Shapiro-Wilk) e de igualdade de variâncias (Bartlett). Para densidade, HT, Db e AB, os testes foram realizados a partir das quatro fitofisionomias que tiveram seus indivíduos inventariados (CD, C, CR e CaC). Já o parâmetro AGB foi analisado para as fitofisionomias anteriormente citadas, assim como para CaS e CaL.

De maneira geral, os quatro parâmetros analisados formaram dois principais grupos, segundo o teste Tukey, separando fitofisionomias com comportamentos extremos como CD e CaC. Ocorreu baixa sensibilidade na separabilidade para o restante das fitofisionomias (Figura 5.4).

Nesse estudo, o cerrado *sensu stricto* foi subdividido em cerrado denso (CD), cerrado típico (C) e cerrado ralo (CR), como descrito anteriormente. Essa opção justifica-se diante do objetivo central desse estudo, que visa à caracterização espectral do gradiente de vegetação encontrado na ESEC-AE. No entanto, grande parte dos estudos desenvolvidos em Cerrados agrupam CD, C e CR em cerrado *sensu stricto*, de acordo com o sistema de classificação proposto por Ribeiro e Walter (1998), pela sua proximidade em termos estruturais.

Figura 5. 4. Box-plot da distribuição dos parâmetros (a) densidade (indivíduos por hectare), (b) altura total média, (c) diâmetro médio (cm), (d) área basal (metros quadrados por hectare). Letras diferentes mostram diferenças significativas entre fitofisionomias, segundo o teste Tukey (α = 0,05).



Para as densidades de indivíduos foi possível afirmar que CD  $(2415\pm388 \text{ ind.ha}^{-1})$  possui maior densidade do que CaC  $(1162\pm273 \text{ ind.ha}^{-1})$ . Já a fitofisionomia C, ora se confunde com CD, ora com CR, assim como CR que se confundiu com C e CaC. As alturas médias totais formaram dois principais grupos. O teste de comparação de médias confirmou a superioridade das alturas médias dos indivíduos de parcelas de CD em comparação a CR e CaC. C ocorreu como estágio intermediário. Comportamento similar foi observado na análise dos diâmetros médios, demonstrando a superioridade de CD em relação a CaC. As fitofisionomias C e CR apresentaram comportamento

intermediário. A área basal formou dois grupos distintos. CD e C foram similares em valores de área basal e superiores a CR e CaC. Estes também demonstraram similaridade em termos de área basal. Diferenças significativas já foram relatadas, principalmente com relação à densidade e área basal, entre cerrado *sensu stricto* e campo cerrado por Uhlman et al. (1998).

Estudos que abordaram o cerrado sensu stricto (ASSUNÇÃO; FELFILI, 2004; FELFILI et al., 1992; FELFILI et al., 1994; FELFILI et al., 2001; FELFILI; SILVA JÚNIOR, 1993; REZENDE et al., 2006; RIBEIRO et al., 2011; SOUZA et al., 2010) relataram grandes variações em sua estrutura. Ribeiro et al. (2011) encontraram valores médios de densidade de 2086 ind.ha<sup>-1</sup> e área basal de 14,9 m<sup>2</sup>.ha<sup>-1</sup> em cerrado sensu stricto de Minas Gerais. Rezende et al. (2006) obtiveram valores médio relativamente baixos para área basal (6,64±0,84 m<sup>2</sup>.ha<sup>-1</sup>) na Fazenda Água Limpa em Brasília (DF). Felfili e Silva-Júnior (1996), em estudo do cerrado sensu stricto na ESEC-AE, encontraram densidade média de 1396 ind.ha<sup>-1</sup> e 10,8 m<sup>2</sup>.ha<sup>-1</sup> de área basal média. Esse último estudo encontrou valores médios correspondentes ao cerrado ralo (1635±394 ind.ha<sup>-1</sup> e 11,72±4,68 m<sup>2</sup>.ha<sup>-1</sup> <sup>1</sup>). Estudos mais específicos como os de Andrade et al. (2002), em cerrado denso na Reserva Ecológica do IBGE em Brasília (DF), obtiveram densidade de 1964 ind.ha<sup>-1</sup> e área basal (AB) de 13,28 m<sup>2</sup>.ha<sup>-1</sup>. Moreno et al. (2008) reportaram 4742 ind.ha<sup>-1</sup> e AB de 23,6 m<sup>2</sup>.ha<sup>-1</sup> para a mesma fitofisionomia amostrada na Estação Ecológica do Panga em Uberlândia (MG). Os valores encontrados para cerrado denso nesse estudo (2415±388 ind.ha<sup>-1</sup> e 22,03±1,54 m<sup>2</sup>.ha<sup>-1</sup> de AB média) estão dentro do intervalo de valores relatados na literatura.

Os valores médios de AGB variaram de  $34,46\pm2,7$  t.ha<sup>-1</sup> (CD) a  $3,98\pm0,7$  t.ha<sup>-1</sup> (CaL) (Figura 5.5). De acordo com o teste Tukey, as médias de AGB das seguintes fitofisionomias não diferiram significativamente: CR ( $14,08\pm5,93$  t.ha<sup>-1</sup>) de CaC ( $9,73\pm3,38$  t.ha<sup>-1</sup>); CaC de CaS ( $5,83\pm1,35$  t.ha<sup>-1</sup>) e de CaL. As parcelas de CD foram superiores em valores médios de AGB, diferindo significativamente de C ( $26,56\pm6,93$  t.ha<sup>-1</sup>). C também diferiu das demais fitofisionomias.

Figura 5. 5. Box-plot da distribuição da AGB nas fitofisionomias amostradas. Letras diferentes mostram diferenças significativas entre fitofisionomias, segundo o teste Tukey ( $\alpha = 0,05$ ).



Miranda (2012) fez um levantamento bibliográfico dos estudos de biomassa no Cerrado em 127 localidades para as formações savânicas e 22 localidades para as campestres. Nas formações savânicas, o valor médio de AGB dos indivíduos lenhosos vivos foi de 24,25 t.ha<sup>-1</sup>, variando de 3,31 t.ha<sup>-1</sup> (OTTMAR et al., 2001) a 67,65 t.ha<sup>-1</sup> (RIBEIRO et al., 2011). Para formações campestres, a AGB média total resultante foi de 6,70 t.ha<sup>-1</sup>, variando de 1,09 t.ha<sup>-1</sup> (KAUFFMAN et al., 1994) a 15,60 t.ha<sup>-1</sup> (OTTMAR et al., 2001) em áreas localizadas no DF. As estimativas (CD, C, CR e CaC) e medições (CaS e CaL) de AGB obtidas nesse estudo corroboram com as dos autores já citados anteriormente, em valores médios de AGB para o Cerrado.

Apenas como forma de ilustrar a distribuição da biomassa dos indivíduos inventariados dentro da parcela, foi realizado o posicionamento X Y de cada indivíduo, tendo como referência a própria parcela que posteriormente foi georreferenciada. Esse procedimento
foi executado em algumas parcelas das fitofisionomias cerrado típico (C), cerrado ralo (CR) e campo cerrado (CaC), representadas em três parcelas (Figura 5.6).





#### 5.2. Caracterização espectro-sazonal das fitofisionomias

Nesta seção, o comportamento sazonal das diferentes fitofisionomias existentes na ESEC-AE será analisado inicialmente usando as seis datas de obtenção dos dados Hyperion. Posteriormente, uma data do período chuvoso e outra do período seco serão

usadas para discussão da discriminação das fitofisionomias nestes períodos. A mata de galeria foi considerada nas análises dessa seção, como anteriormente descrito.

#### 5.2.1. Análise sazonal por atributos hiperespectrais

O comportamento sazonal médio de alguns dos principais índices de vegetação de bandas estreitas do Hyperion/EO-1 foi analisado usando as seis imagens obtidas em 2014. Duas das imagens foram obtidas no período chuvoso (março e abril) e as demais correspondem ao período seco (maio, junho, julho e agosto).

A variação dos IVs NDVI, RENDVI, NDII e VARI e a precipitação acumulada em cada mês foram plotadas na Figura 5.7. Com dossel estabelecido, sem queda significativa das folhas (vegetação perenifólia) e ocorrendo ao longo dos cursos d'água, a mata de galeria (MG) mantém comportamento estável dos IVs ao longo dos meses analisados. No entanto, para o índice NDII, relacionado ao conteúdo de água nas folhas (ROBERTS et al., 2011), o comportamento dessa fitofisionomia foi considerado atípico, resultando em valores um pouco mais elevados no período seco, possivelmente causado por ruídos próximos a feição de vapor d'água em 823 nm, comprimento de onda utilizado na formulação do índice (Tabela 4.3). O cerrado denso (CD) e cerrado típico (C) mostraram comportamentos sazonais similares ao longo dos meses, diminuindo da estação chuvosa para a seca. Essas duas fitofisionomias possuem dosséis mais fechados com abundância de indivíduos arbóreo-arbustivos e menor exposição do estrato herbáceo-graminóide, que por sua vez, é menos denso daqueles substratos das formações mais abertas. Por conseguinte, apresenta exposição do solo em sua configuração. Quando comparado com as áreas de campo Limpo (CaL) e campo Sujo (CaS), o decréscimo dos IVs no período seco de CD e C é menos acentuado. Isto ocorre pela predominância dos indivíduos arbóreos em CD e C, cujo sistema radicular mais extenso penetra nas camadas mais profundas do solo. Isto, mantém certo grau de umidade mesmo em épocas secas, minimizando assim as variações de déficit hídrico (PALHARES et al., 2010). Isto faz com que certas espécies mantenham suas copas em processo fotossinteticamente ativo. A menor frequência de indivíduos arbóreoarbustivos em cerrado ralo (CR) e campo cerrado (CaC) resulta na maior contribuição do estrato arbustivo-herbáceo (distribuído num tapete geralmente graminóide) na resposta espectral de suas amostras, com reduções mais acentuadas dos IVs na transição do período chuvoso para o seco. CR e CaC se confundem no período chuvoso, com valores de IVs muito próximos, principalmente aos IVs associados à estrutura (NDVI e VARI) e fisiologia (RENDVI).

Figura 5. 7. Comportamento sazonal médio (n = 100 pixels por tipologia), no período de março a agosto de 2014, dos índices de vegetação (a) NDVI, (b) RENDVI, (c) NDII e (d) VARI. O desvio-padrão é indicado, assim como a precipitação acumulada em cada mês analisado.



Como mencionado anteriormente, as áreas de campo sujo (CaS) e campo limpo (CaL) sofreram os decréscimos mais acentuados nos IVs ao longo dos meses. Decorrente do volume precipitado no mês de março, os IVs destas duas fitofisionomias aumentaram de março para abril e diminuíram nos meses seguintes seguindo o padrão de precipitação pluviométrica e a consequente resposta da capacidade fotossinteticamente ativa das

tipologias de vegetação. As parcelas de campo limpo são as mais sensíveis à sazonalidade das chuvas, por sua vegetação ser basicamente composta por plantas herbáceas e gramíneas com raízes pouco profundas (FELFILI et al., 2008). Portanto, estas plantas se tornam rapidamente senescente com o início do período seco, pois suas raízes se encontram em camadas de solo em que há redução abrupta da disponibilidade hídrica na estação seca, conforme também constatado por Palhares et al. (2010).

A Figura 5.8 apresenta os espectros de reflectância média, representativos das fitofisionomias nos períodos chuvoso (março de 2014) e seco (agosto de 2014). Além da exposição em maior ou menor grau do estrato herbáceo-graminóide, as variações de fenologias foliares entre as espécies lenhosas (espécies decíduas, semidecíduas e sempre-verdes), ocorrendo lado a lado na mesma região (PALHARES et al., 2010), produzem valores de reflectância espectral distintos entre os períodos. De maneira geral, a reflectância média na faixa do visível, infravermelho de ondas curtas 1 (SWIR 1 – 1550 a 1750 nm) e infravermelho de ondas curtas 2 (SWIR 2 – 2000 a 2400 nm) aumenta com o adensamento da vegetação, do campo limpo a mata de galeria. O contrário foi observado no infravermelho próximo (IVP), de 750 a 1100 nm.

Figura 5. 8. Espectros de reflectância média das fitofisionomias existentes na ESEC-AE nos períodos (a) chuvoso e (b) seco.



A região do visível é marcada pela absorção da radiação por pigmentos fotossintetizantes como a clorofila, carotenoides e antocianinas (JENSEN, 2007). Fitofisionomias mais abertas sofreram aumento na reflectância média principalmente na região do vermelho (660 nm), no período seco, com a diminuição nas quantidades de pigmentos fotossintetizantes (SOUZA et al., 2010). Do período chuvoso para o seco, o pico de reflectância no verde deixa de ser observado nas áreas de CaL. O aumento da reflectância no visível é resultante do processo de senescência das gramíneas, que contribui em maior ou menor grau para a reflectância média da fitofisionomia dependendo do nível de exposição desse substrato.

As modificações da reflectância na região do infravermelho próximo (IVP) são causadas por alterações na estrutura foliar/dossel (ASNER, 2008). As formações florestais, como a mata de galeria, possuem maior complexidade do dossel apresentando assim maior reflectância devido ao espalhamento da radiação na região do IVP. As variações em sua estrutura e no comportamento do dossel quanto ao grau de cobertura são mínimas, resultando, por conseguinte, em pequenas modificações em seu comportamento espectral ao longo do ano. Já as fitofisionomias savânicas e campestres, que são compostas por indivíduos arbóreo-arbustivos como CD, C, CR e CaC (FELFILI et al., 2008), tem em sua estrutura foliar um comportamento modificado na estação seca pela presença de espécies decíduas ou semidecíduas nos vários estratos, reduzindo a reflectância na região do IVP. Esse comportamento torna estas fitofisionomias, ao longo do gradiente de vegetação, espectralmente um pouco mais semelhantes no período seco. No período de estiagem, com aumento do déficit hídrico, ocorre considerável aumento da reflectância média na região do SWIR 1 e SWIR 2, regiões espectrais associadas ao conteúdo de água na vegetação, e em menor grau, ao conteúdo de nitrogênio, celulose e lignina (ROBERTS et al., 2011). É importante mencionar que a região do SWIR 2 apresenta-se bastante ruidosa nos dados Hyperion da época seca, prejudicando as análises de índices hiperespectrais como o CAI (Cellulose Absorption Index).

A Figura 5.9 resume as diferenças entre as fitofisionomias nas três principais regiões do espectro: vermelho (660 nm), IVP (864 nm) e SWIR 1 (1648 nm). Na faixa correspondente ao vermelho, diferenças significativas (p<0,05) foram constatadas para todas as fitofisionomias no período chuvoso. Já no período seco, CR e CaC não

apresentaram diferenças significativas para a reflectância média desse comprimento de onda. No IVP (864 nm), ocorreram as maiores confusões entre as fitofisionomias. No período chuvoso, não foram observadas diferenças estatisticamente significativas entre C e CR ou entre CaC e CaS. No período seco, tais diferenças em 864 nm também não foram significativas entre CR e CaC ou entre CaS e CaL. A região do SWIR 1 foi mais favorável à separabilidade das fitofisionomias no período seco, resultado consistente com as observações feitas por Miura et al. (2003) em estudo das fitofisionomias do Parque Nacional de Brasília. Apenas as classes CaS e CaL não foram significativamente diferentes. Já no período chuvoso, ocorreu a diferenciação de apenas quatro grupos de tipologias, ao passo que as fitofisionomias CD, C e CaC não apresentaram diferenças em relação à reflectância média, assim como ocorreu entre CR e CaL.

Figura 5. 9. Boxplot para comparação das reflectâncias médias no período chuvoso e seco por meio da ANOVA e teste de Tukey (letras diferentes indicam diferença significativa com α=5%), no (a) vermelho (660 nm), (b) IVP (864 nm) e (c) SWIR 1 (1648 nm).



A porcentagem de mudança de cada índice foi calculada como forma de verificar, em uma mesma escala, qual deles se mostrou mais sensível às variações sazonais de cada fitofisionomia. A média, desvio padrão e porcentagem de mudança para todos os índices estão descritos no Apêndice A. As características de alguns IVs podem ser observadas na Figura 5.10. As porcentagens negativas significam decréscimo no valor do índice no decorrer da estação chuvosa para a seca. Dentre os IVs que apresentaram essa característica, podem-se destacar o NDII, NDVI e VARI. O SIPI apresentou comportamento contrário pelo fato de sua formulação ser sensível à relação entre carotenoides e clorofila. Seu valor aumenta com a senescência da vegetação, pois, com a degradação dos pigmentos foliares e perda da capacidade fotossintética, aumenta a reflectância, principalmente em 680 nm.

Figura 5. 10. Porcentagem de mudança do período chuvoso para o seco, dos índices NDII, NDVI, SIPI e VARI para cada fitofisionomia analisada.



Na transição das fitofisionomias com maior densidade de indivíduos arbóreo-arbustivos para as de menor densidade, observaram-se variações mais acentuadas nos índices de maneira geral. Isso se deve em parte ao efeito das variações estruturais na configuração da espacialização e volume do dossel, resultando, dentre outros fatores, com o conteúdo de sombra intra-pixels das imagens Hyperion, e também, a maior exposição do substrato herbáceo-graminóide mais sensível às mudanças ambientais, como mencionado anteriormente, sobretudo nas formações savânicas. Os índices que sofreram as maiores variações entre períodos foram NDII e VARI, relacionados respectivamente com conteúdo de água nas folhas e estrutura do dossel. Campo sujo e campo limpo foram as fitofisionomias com maiores variações principalmente para o índice VARI, com um decréscimo do valor deste índice em aproximadamente oito vezes para CaL e três vezes para CaS. Roberts et al. (2011) apontaram o VARI como um dos IVs menos sensíveis à saturação com o aumento de índice de área foliar (IAF), sendo mais sensível às mudanças na fração de cobertura vegetal.

Exemplos de relações entre os pares de alguns dos índices calculados podem ser observados na Figura 5.11. Os gráficos sugerem a existência de relações lineares ou não-lineares entre os pares de IVs plotados em ambos os períodos seco e chuvoso. Entretanto, em geral, ocorre maior separabilidade das fitofisionomias no período seco do que no período chuvoso para os IVs analisados. Mata de galeria e campo limpo apresentaram maior separabilidade pelas suas características extremas de alta e baixa cobertura do solo, respectivamente.



Figura 5. 11. Relações entre (a e b) NDVI e VARI, e (c e d) RENDVI e NDII, nos períodos seco e chuvoso da área de estudo.

Por meio da Figura 5.12, foi possível observar o comportamento das diferentes fitofisionomias com base na profundidade e área das bandas de absorção centradas em 680 nm (clorofila) e 1200 nm (água nas folhas), calculadas pelo método de remoção do contínuo espectral (CLARK; ROUSH, 1984; KOKALY, 2011). O período chuvoso exibe bandas mais profundas e com maiores áreas em 680 e 1200 nm. No período seco,

há forte redução na profundidade das bandas de absorção de clorofila e de água nas folhas, devido a maior quantidade de vegetação não-fotossinteticamente ativa (GALVÃO et al., 2005). Quanto mais aberta for a fitofisionomia, mais acentuadas serão as reduções na profundidade das bandas de absorção, quando se passa do período chuvoso para o seco. Este comportamento é explicado pela maior exposição do estrato herbáceo-graminóide, que se apresenta senescente no período seco. A banda de absorção situada em 1200 nm sofreu maiores reduções entre os períodos.

Figura 5. 12. Relação das profundidades das bandas de absorção de clorofila (680 nm) e de água das folhas (1200 nm), calculadas a partir do método de remoção do contínuo espectral, nos períodos (a) seco e (b) chuvoso. Os resultados para o atributo "área" destas feições são mostrados em (c) e (d).



Em termos de separabilidade entre as fitofisionomias, ocorre maior confusão entre elas quando se utiliza a profundidade em 1200 nm, tanto no período chuvoso quanto no seco. A profundidade em 680 nm mostrou maior separabilidade no período seco, principalmente para as fitofisionomias campestres. A área das bandas de absorção segue padrão similar ao da profundidade no período chuvoso. Porém, no período seco, há uma tendência mais bem definida de discriminação entre as fitofisionomias.

# 5.2.2. Discriminação de fitofisionomias por análise discriminante múltipla (MDA)

#### 5.2.2.1. Atributos de reflectância

A análise discriminante múltipla (MDA) foi aplicada separadamente para cada conjunto de atributos gerados nas etapas anteriores. O objetivo dessa etapa foi analisar a discriminação, baseada em conjuntos de atributos hiperespectrais, entre as diferentes fitofisionomias presentes na área de estudo e entre seus comportamentos nos períodos seco e chuvoso. Conforme descrito no capítulo de metodologia de trabalho, foram selecionados aproximadamente 700 pixels (100 por fitofisionomia) na imagem Hyperion do período chuvoso (março de 2014) e 700 pixels na do período seco (agosto de 2014) para efetivar a MDA. 50% dos pixels em cada imagem e período foram destinados à obtenção das funções discriminantes e 50% para avaliar a precisão da classificação. Com o intuito de produzir funções discriminantes adequadas para cada conjunto de métricas, selecionando as melhores variáveis discriminatórias e reduzindo a alta dimensionalidade dos dados, efetivou-se seleção de atributos pelo método passo-a-passo, já descrito anteriormente.

Os resultados da seleção de atributos de reflectância das 146 bandas do sensor Hyperion para os perídos seco e chuvoso são apresentados na Tabela 5.4. Foram selecionadas 26 bandas para o período chuvoso e 22 bandas para o período seco. Não foi estabelecido um padrão de seleção específico para cada período. Nos dois casos, bandas em diferentes faixas espectrais foram selecionadas para otimizar a separabilidade entre as fitofisionomias.

Período	Bandas selecionadas (nm)														
Chuvoso	467, 1043,	487, 1124,	528, 1245,	609, 1255,	681, 1316,	701, 1527,	711, 1537,	732, 1618,	762, 1709,	772, 1729,	854, 2092,	894, 2193,	1013, 2203		
Seco	518, 1295,	569, 1305,	599, 1558,	620, 1578,	681, 1659,	701, 2193,	711, 2224,	752, 2254,	762, 2304	772,	1154,	1174,	1245,		

Tabela 5. 4. Bandas selecionadas pelo método passo-a-passo para discriminar as fitofisionomias no período chuvoso e no período seco.

As duas primeiras funções discriminantes foram responsáveis por reter 86,0% e 92,7% da variância acumulada dos dados no período chuvoso e seco, respectivamente. Os escores para as duas primeiras funções discriminantes foram plotados na Figura 5.13 para cada período. Conforme observado nas análises anteriores, as fitofisionomias com maior separabilidade foram as de comportamentos extremos em cobertura vegetal do terreno, como mata de galeria (MG) e campo limpo (CaL) (FERREIRA et al., 2007).

Figura 5. 13. Projeção dos escores das fitofisionomias analisadas, nas duas primeiras funções discriminantes para o conjunto reflectância de bandas no período (a) chuvoso e (b) seco.



A partir do mesmo método de seleção passo-a-passo, Vyas et al. (2011) obtiveram um número de 22 bandas espectrais para classificar diferentes espécies em florestas

decíduas na India. Souza et al. (2010) reportaram um número ótimo de 15 bandas para classificar fitofisionomias do Cerrado em Goiás.

A matriz de confusão foi gerada para cada período a partir das amostras de validação para o período chuvoso e seco, respectivamente. Estas estão detalhadas na Tabela B.1 e B.2 do Apêndice B. A utilização da análise discriminante para classificar as amostras de validação produziu as seguintes acurácias de classificação respectivamente para o período chuvoso e seco: 82,2-83,7% (CD), 47,7-50,0% (C), 69,6-64,4% (CR), 87-73,2% (CaC), 80-81,8% (CaS), 74,4-86,7% (CaL) e 97,6-97,6% (MG). A menor acurácia de classificação foi para a classe cerrado típico (C) nos dois períodos. Souza et al. (2010), em trabalho com fitofisionomias do Cerrado em Goiás apenas no período seco, descreveram as classes CaL e CaS como as de menor acurácia, diferindo dos resultados encontrados neste trabalho. Os resultados obtidos na ESEC-AE mostraram que, do período chuvoso para o seco, a acurácia aumentou em 12,3% na classe CaL, diminuindo em 13,8% para CaC. A acurácia global foi de 76,8% para o período chuvoso e 76,6% para o seco, resultando em um mesmo índice Kappa de 0,73. De acordo com o teste Z (p < 0.01) para comparação entre valores de Kappa, não ocorreram diferenças estatisticamente significativas entre as duas classificações feitas com dados de reflectância no período seco e chuvoso.

### 5.2.2.2. Índices de vegetação (IVs)

Para o conjunto de IVs, a seleção passo-a-passo de atributos escolheu dez IVs no período chuvoso e nove no seco, de um total de 22 índices hiperespectrais gerados (Tabela 5.5). ARI, EVI, MSI, NDII, PSSR, RENDVI e SIPI foram IVs comuns aos dois períodos. Os índices MCARI, NDVI e PRI foram selecionados apenas para o período chuvoso, assim como PSRI e VOG foram selecionados apenas para o seco.

Tabela 5. 5. Índices de Vegetação selecionados pelo método passo-a-passo para discriminar as fitofisionomias no período chuvoso e no período seco.

Período	Índices de vegetação selecionados								
Chuvoso	ARI , EVI , MCARI , MSI , NDII, NDVI, PRI, PSSR, RENDVI , SIPI								
Seco	ARI , EVI , MSI, NDII, PSRI, PSSR, RENDVI , SIPI , VOG								

As duas primeiras funções discriminantes foram responsáveis por reter 91,7% e 95,7% da variância acumulada dos dados no período chuvoso e seco, respectivamente. Os escores para as duas primeiras funções discriminantes relacionadas com os IVs estão representados na Figura 5.14 para cada período. Aparentemente há um ganho na discriminação não apenas das fitofisionomias com comportamentos extremos (MG e CaL), mas também nas demais classes analisadas no período seco.

Figura 5. 14. Projeção dos escores das fitofisionomias analisadas, nas duas primeiras funções discriminantes para o conjunto de índices de vegetação no período (a) chuvoso e (b) seco.



Para comprovar a hipótese levantada no parágrafo anterior, as matrizes de confusão foram geradas a partir das amostras de validação. Os resultados estão detalhados na Tabela B.3 e B.4 do Apêndice B. A classificação produziu as seguintes acurácias de classificação para o período chuvoso e seco, respectivamente: 75,6-88,4% (CD), 34,1-61,4% (C), 69,6-62,2% (CR), 78,3-80,5% (CaC), 82,2-79,5% (CaS), 73,8-91,1% (CaL) e 100,0-95,1% (MG). A menor acurácia de classificação foi obtida para a classe cerrado típico (C), principalmente no período chuvoso, ao registrar maior confusão com CR e CaC. No entanto, para a mesma classe, o ganho foi 27,3% quando analisada no período seco. CaL também apresentou um ganho de acurácia de 17,3% entre períodos. A acurácia global foi de 73,2% para o período chuvoso e 79,5% para o seco. O ganho de

6,3% na acurácia no período seco foi considerado significativo (p<0,01), de acordo com o teste Z. O índice Kappa variou de 0,69 no período chuvoso para 0,76 no período seco.

O comportamento dos conjuntos reflectância e IVs diferiu com relação aos períodos analisados. Uma possível explicação é a flexibilidade decorrente da seleção de atributos dentre um grande número de bandas espectrais, que propicia bons resultados em ambos os períodos. Já o ganho na classificação no conjunto IVs, no período seco, pode estar condicionado à formulação dos IVs, que são compostos por bandas fixas que se comportam de maneira diferente em cada período, favorecendo o seco neste caso.

#### 5.2.2.3. Parâmetros de bandas de absorção

Os parâmetros descritores das seis bandas de absorção posicionadas em 680 nm, 980 nm, 1200 nm, 1700 nm, 2100 nm e 2300 nm também foram testados para fins de classificação. Foram selecionados oito parâmetros no período chuvoso e sete no período seco, de um total de 24 métricas (Tabela 5.6). Profundidade, Largura e Área centrada na banda 680 nm, assim como Área em 980 nm, Largura em 1700 nm e Área em 2100 nm foram parâmetros comuns aos dois períodos. A banda centrada em 1200 nm, relacionada ao conteúdo de água nas folhas (GALVÃO et al., 2005), foi selecionada apenas para o período chuvoso, por meio de sua Área.

Tabela 5. 6. Parâmetros descritores de bandas de absorção, calculados pelo método do contínuo espectral e selecionados pelo procedimento passo-a-passo para discriminar as fitofisionomias no período chuvoso e no período seco.

Período	Parâmetros de bandas de absorção selecionadas
Chuvoso	Profundidade 680nm, Largura 680nm, Área 680nm, Profundidade 980nm, Área 980nm,
	Área 1200nm, Largura 1700nm, Área 2100nm
Seco	Profundidade 680nm, Largura 680nm, Área 680nm, Largura 980nm, Área 980nm,
	Largura 1700nm, Área 2100nm

As duas primeiras funções discriminantes associadas aos parâmetros das bandas de absorção foram responsáveis por 96,6% e 98,5% da variância acumulada dos dados no período chuvoso e seco, respectivamente. Os escores para as duas primeiras funções discriminantes estão representados na Figura 5.15 para cada período. É visível o ganho na separabilidade em praticamente todas as fitofisionomias do período chuvoso para o

seco. A senescência mais acentuada das gramíneas, em relação aos indivíduos arbóreoarbustivos (PALHARES et al., 2010), resulta em maiores diferenças na concentração de pigmentos foliares ao longo do gradiente de vegetação (CARVALHO et al., 2007). Dessa forma, as diferenças antes sutis durante a estação chuvosa, pelo vigor tanto do estrato herbáceo-graminóide, quanto do estrato arbóreo-arbustivo, se tornam mais acentuadas no período seco, para bandas relacionadas com a concentração de clorofila e conteúdo hídrico nas folhas.

Figura 5. 15. Projeção dos escores das fitofisionomias analisadas nas duas primeiras funções discriminantes para o conjunto de parâmetros de bandas de absorção no período (a) chuvoso e (b) seco.



As matrizes de confusão geradas a partir das amostras de validação para cada período foram apresentadas nas Tabelas B.5 e B.6 do Apêndice B. A classificação produziu as seguintes acurácias para os períodos chuvoso e seco, respectivamente: 54,0-64,0% (CD), 42,0-66,0% (C), 50,0-44,0% (CR), 54,0-64,0% (CaC), 64,0-66,0% (CaS), 68,0-76,0% (CaL) e 88,0-100,0% (MG).

Ocorreu um ganho de 24% na classificação da fitofisionomia C, do período chuvoso para o seco. Essa classe, considerada de transição no espaço de atributos estruturais

entre um cerrado ralo e aquele tipologicamente denso, foi a de menor acurácia na classificação. Para esse conjunto de atributos, a classe MG foi confundida com CD no período chuvoso. No entanto, no período seco, a acurácia para a MG foi de 100%. A acurácia global e o índice Kappa foram 60,0% e 0,53, respectivamente, para o período chuvoso, e 68,6% e 0,63 para o período seco. O ganho de 8,6% na acurácia para o período seco foi considerado significativo (p<0,01).

#### 5.2.2.4. Análise conjunta de todos os atributos

Após a análise de cada conjunto de atributos separadamente, MDA foi aplicada sobre o conjunto total de variáveis (reflectância, IVs, bandas de absorção) com o objetivo de avaliar possíveis ganhos na acurácia da classificação das fitofisionomias analisadas. Dentre o conjunto total de atributos testados, foram selecionados no período chuvoso 25 bandas espectrais do Hyperion, quatro IVs e quatro parâmetros da banda de absorção posicionada em 680 nm (clorofila). No período seco, os atributos selecionados foram 19 bandas espectrais, cinco IVs e quatro parâmetros associados com bandas de absorção posicionadas em 680 nm (clorofila) e 980 nm (água foliar) (Tabela 5.7).

Tabela 5. 7. Seleção dos melhores atributos para discriminar as fitofisionomias no período chuvoso e seco, considerando o conjunto total de variáveis submetidas para MDA (reflectância, IVs e parâmetros descritores de bandas de absorção).

Período	Parâmetros selecionados							
Chuvoso	467, 477, 487, 609, 650, 671, 681, 701, 711, 732, 762, 772, 854, 894, 993, 1013, 1043, 1194,							
	1245, 1255, 1527, 1618, 1739, 2082, 2203, SIPI, RENDVI, PSSR, MCARI,							
	Profundidade, Largura, Área e Assimetria 680 nm							
Seco	498, 599, 620, 681, 701, 732, 752, 782, 1094, 1164, 1245, 1305, 1558, 1578, 1669, 1679, 1729,							
	2224, 2254, RENDVI, PSSR, PSRI, MCARI, NDII, Profundidade, Largura e Área 680 nm e							
	Profundidade 980 nm							

Quando o MDA foi aplicado sobre o conjunto total de atributos, as duas primeiras funções discriminantes foram responsáveis por 87,0% e 93,0% da variância acumulada dos dados no período chuvoso e seco, respectivamente. Os escores para as duas primeiras funções discriminantes estão representados na Figura 5.16 para cada período. No período seco, as amostras de mesma classe apresentaram comportamento mais adensado do que no período chuvoso, resultando em uma maior separabilidade aparente.

Figura 5. 16. Projeção dos escores das fitofisionomias analisadas nas duas primeiras funções discriminantes para todos os atributos no período (a) chuvoso e (b) seco.



As matrizes de confusão geradas a partir das amostras de validação para o período chuvoso e seco, respectivamente, estão detalhadas nas Tabelas B.7 e B.8 do Apêndice B. As acurácias de classificação para o período chuvoso e seco foram: 80,0-83,7% (CD), 56,8-65,9% (C), 76,1-80,0% (CR), 91,3-82,9% (CaC), 84,4-88,6% (CaS), 81,4-91,1% (CaL) e 100,0-91,1% (MG). A acurácia global foi de 81,4% para o período chuvoso e 84,2% para o seco. O ganho em 2,8% na acurácia do período chuvoso para o seco foi resultante da melhor classificação principalmente das classes de cerrado típico (C) e campo limpo (CaL), resultado considerado significativo (p<0,01). Os valores do índice Kappa foram de 0,78 e 0,82 para o período chuvoso e seco, respectivamente.

Quando comparado com o conjunto total de atributos, as maiores diferenças entre períodos foram reportadas pelas métricas de bandas de absorção. Porém, a acurácia global foi considerada baixa (60% para o período chuvoso e 68,6% para o período seco). Bandas ruidosas em 2100 nm foram selecionadas nos dois períodos, podendo causar algum tipo de influência na classificação geral, reduzindo os acertos das classes. A classificação utilizando todos os atributos produziu melhores resultados para os dois períodos. O uso de MDA, com a inclusão de diferentes atributos hiperespectrais, também foi analisado por Galvão et al. (2005) em abordagem próxima a utilizada neste

estudo. Os autores utilizaram MDA na discriminação de cinco variedades de cana-deaçúcar no Sudeste do Brasil, obtendo bons resultados com a combinação geral de diferentes atributos.

Millán et al. (2014) observaram que, durante a estação seca, sensores orbitais capturam de forma mais eficiente as diferenças estruturais na vegetação, correspondentes à área basal, densidade de árvores e condições de sub-bosque expressas através da abertura do dossel. Os mesmos autores afirmam também que, durante o período chuvoso, a resposta da vegetação pode se confundir pela maior interferência do dossel, mais vigoroso nessa época. No entanto, como verificado nesse estudo, ocorreu discriminação das fitofisionomias quando a resposta espectral foi analisada em uma única banda correspondente ao vermelho (680 nm), indicando também possibilidades de discriminação no período chuvoso em bandas particulares, que representem a máxima separabilidade entre as fitofisionomias analisadas.

## 5.3. Modelagem da AGB com atributos hiperespectrais e PLSR

Conforme mencionado anteriormente, imagens Hyperion não foram obtidas em época simultânea a da coleta de dados em campo em 2015, ou em meses próximos no período seco desse ano. A imagem Hyperion utilizada na modelagem da AGB foi a correspondente ao período seco de 2014 (julho). A decisão de modelar a biomassa de 2015 com a imagem de 2014 foi feita com base em dois pressupostos. O primeiro foi a semelhança no comportamento da precipitação ao longo dos dois anos analisados, conforme descrito anteriormente na seção Metodologia de Trabalho. Essa característica faz com que a vegetação tenha, numa premissa geral, um padrão sazonal semelhante ao longo desses dois anos. O segundo pressuposto se baseou no uso de uma imagem RapidEye adquirida simultaneamente às atividades de campo. Usando a imagem RapidEye de 2015, obteve-se a relação do NDVI com a biomassa observada em campo. Usando a imagem Hyperion de 2014 e a função de resposta dos filtros do RapidEye, simulou-se a resposta espectral desse sensor a partir dos dados Hyperion, obtendo-se também a relação do NDVI simulado com a biomassa observada em campo. A comparação das relações do NDVI com a AGB para a imagem Rapideye simulada a partir da imagem Hyperion 2014 e para a imagem Rapideye de 2015, adquirida concomitante às atividades de campo, é mostrada na Figura 5.17. Os resultados foram

consistentes entre os dois anos, com coeficientes de correlação (r) de +0,86 para 2014 e +0,85 para 2015. Diante desse resultado, optou-se pelo prosseguimento da modelagem de AGB medida no período seco de julho de 2015 com dados hiperespectrais do Hyperion obtidos no mesmo período em julho de 2014.

Figura 5. 17. Relação do NDVI com a biomassa (AGB) para a imagem Rapideye simulada a partir da imagem Hyperion 2014, e para a imagem Rapideye 2015, adquirida concomitante ao campo.



A seguir são apresentados cada um dos cinco modelos propostos neste trabalho. Ainda que a análise tenha sido feita com o objetivo de entender os aspectos da vegetação, vale ressaltar que a biomassa foi modelada utilizando todas as fitofisionomias, com o intuito de construir modelos generalistas para cada conjunto de variáveis independentes. No modelo Geral, foram reunidas todas as variáveis X dos modelos anteriores, além das razões de reflectância, resultando em 10777 atributos hiperespectrais como variáveis independentes. Para cada conjunto de atributos, foi realizada uma análise exploratória dos dados, anteriormente a modelagem da AGB.

### 5.3.1. Modelagem da AGB com Reflectância

#### 5.3.1.1. Análise exploratória da reflectância

A Figura 5.18 mostra o grau de correlação entre a reflectância de cada uma das 146 bandas espectrais do Hyperion e a biomassa da vegetação (AGB).

Figura 5. 18. Correlação entre AGB e Reflectância de 146 bandas do sensor Hyperion. Valores acima de 0,4 e abaixo de -0,4 foram considerados significativos (p<0,05).



Os comprimentos de onda que apresentaram as melhores correlações foram analisados em gráficos de dispersão para avaliar seu comportamento diante de cada amostra de campo (Figura 5.19). A melhor correlação positiva foi obtida com a reflectância em 874 nm, região do infravermelho próximo (IVP), resultando em um coeficiente de correlação (r) de +0,66. Esse resultado indica que, quanto maior for a reflectância em 874 nm, maior será a biomassa das fitofisionomias. A melhor correlação negativa foi obtida com a reflectância em 1719 nm, região do SWIR 2, com um r de -0,76. Portanto, quanto menor for a reflectância em 1719 nm, maior será a biomassa. Nessa região do espectro, há uma forte relação com o conteúdo de água na vegetação que absorve radiação (PONZONI et al., 2012). Os resultados da Figura 5.19 refletem a transição das fitofisionomias de cerrado com menor AGB (p.ex., CaL e CaS) para as de maior AGB (p.ex., C e CD), com estas últimas fitofisionomias tendo maiores valores de reflectância no IVP em 874 nm e menores valores no SWIR 1 em 1719 nm.



Figura 5. 19. Relação entre biomassa (AGB) e reflectância (a) em 874 nm, (b) 1719 nm (p<0,05).

## 5.3.1.2. Modelagem PLSR da reflectância

Os escores referentes aos dois primeiros fatores (PCs) do modelo PLSR de reflectância expressam como as amostras são projetadas ao longo de cada componente ou fator. A análise dos dois primeiros fatores é especialmente útil, uma vez que estes representam a maior parte de variância dos dados analisados (Figura 5.20).

Figura 5. 20. Distribuição dos escores nos dois primeiros fatores para os dados de calibração do modelo reflectância. Valores entre parênteses explicam a variância de X e de Y respectivamente, em cada fator analisado. Amostras fora da Elipse de Hotelling T<sup>2</sup> apresentam comportamentos extremos (α = 0,05).



No modelo reflectância, PC1 e PC2 explicaram um total de 73% da variância de X e 66% da variância em Y dos dados de calibração. Observou-se a formação de uma tendência de agrupamento apenas para as amostras de campo limpo (CaL). A formação de agrupamentos reflete a semelhança das amostras com relação às variáveis analisadas. As outras fitofisionomias permaneceram misturadas sem a formação de grupos específicos. A parcela de campo limpo (P39) apresentou comportamento passível de investigação por estar fora dos limites da Elipse de Hotelling T<sup>2</sup>. Este comportamento foi verificado por meio da análise de influência.

Os *Loadings* (fatores de peso) expressam como as variáveis são projetadas ao longo de cada fator do modelo. Na Figura 5.21, os comprimentos de onda (variáveis X) foram agrupados em regiões do espectro para que a relação dentro desses grupos e entre variáveis X e Y pudesse ser mais bem compreendida.

A relação da variável Y (biomassa) foi positiva para o IVP, projetada em uma mesma direção no gráfico, e negativa para o Visível, SWIR 1 e SWIR 2, projetada em direções opostas. Algumas bandas em comprimentos de onda na região do IVP foram projetadas próximas ao centro, demonstrando ter baixa relação com a biomassa. Dentre elas, podese destacar as posicionadas em 1124 nm, 1174 nm, 1245 nm, 1285 nm e 1302 nm.

Figura 5. 21. Distribuição dos *loadings* nos dois primeiros fatores para os dados de calibração do modelo PLSR de reflectância. Valores entre parênteses explicam a variância de X e de Y respectivamente, em cada fator analisado.



A distribuição dos escores está diretamente relacionada à distribuição dos *loadings*. Quando os dois gráficos são analisados concomitantemente, é possível compreender a influência de cada variável nas diferenças entre as amostras. Variáveis na região do IVP exerceram grande influência no comportamento de amostras do cerrado denso (CD) e cerrado típico (C), ou seja, em amostras que possuam maiores valores de biomassa. Já as faixas do visível, SWIR 1 e SWIR 2 exerceram grande influência em amostras de baixa biomassa como campo limpo (CaL).

Com a reflectância de 146 bandas usada como dados de entrada (variáveis X), foram necessários quatro fatores (PCs) para alcançar o melhor ajuste do modelo, ou seja, a variação dos dados de validação foi explicada ao maximizar a variância total explicada de Y em 64,18%, e minimizar a variância total residual (RMSE) em 6,72 t.ha<sup>-1</sup> (Figura 5.22). A complexidade e variabilidade da reflectância ao longo do espectro eletromagnético fez com que um número maior de fatores fosse necessário para explicar a variabilidade dos dados.

Figura 5. 22. Comportamento da (a) variância explicada de Y; e do (b) RMSE em cada fator do modelo PLSR de reflectância para calibração e validação.



Na análise de influências, a amostra P39 (CaL), indicada pelo gráfico de escores como um possível *outlier*, apresentou *leverage* de 0,57, valor considerado alto (limite=0,33; p<0,005), demonstrando ter alta influência neste modelo. No entanto, como apresentou variância residual (0,25) abaixo do limite ( $F_{crit}$ =0,88; p<0,005), sua exclusão não foi necessária (Figura 5.23).

Figura 5. 23. Comparação entre a variância residual de X (limite  $F_{crit} = 0.88$ ) e a *Leverage* (limite = 0.33), verificando a influência de cada amostra na modelagem da AGB pela reflectância de 146 bandas como variáveis independentes X.



A validação do modelo reflectância pelo método de validação cruzada resultou em um coeficiente de determinação (R<sup>2</sup>) de 0,64. O RMSE de 6,72 t.ha<sup>-1</sup> representa 40% da média dos valores observados. Analisando o modelo de maneira geral, a biomassa predita tende a subestimação em 53% das amostras, principalmente para as parcelas com valores de biomassa extremos, como as de cerrado denso (CD) e campo limpo (CaL). Valores medianos de AGB observada em cerrado ralo (CR), campo cerrado (CaC) e campo sujo (CaS) tenderam a superestimação (Figura 5.24).

Figura 5. 24. Valores de AGB observados em relação aos valores preditos na validação cruzada do modelo PLSR de reflectância.



As amostras de campo sujo apresentaram erro relativo elevado, superestimando a AGB em 287% na parcela 40 e 195% na parcela 42. Possivelmente, este fato ocorreu devido as diferentes características observadas em campo. Na parcela 40 foi observada a presença de indivíduos de porte arbóreo nas bordas da parcela por estar numa zona de contato fitofisionômico (Figura 5.25-a), porém estes não foram amostrados por não pertencerem aos seus limites. A influência desses indivíduos pode ter contaminado os pixels de borda, causando a superestimativa da AGB, considerando que o pixel amostrado na imagem Hyperion difere do tamanho da parcela em campo, incorporando

outros elementos da paisagem na resposta espectral da parcela. O mesmo comportamento foi analisado na parcela 42, amostrada num sitio em contato com a vereda, local de abundante invasão de *Trembleya parviflora*. Estas também foram observadas nas bordas da parcela, o que pode influenciar a resposta da mesma (Figura 4.25-b). *Trembleya parviflora* é uma espécie de planta pioneira associada a solos úmidos, porém não encharcados, que quando introduzidas em outras áreas, fora de sua distribuição original, transforma-se em invasora (MEYER, 1998). Embora seja uma espécie da flora nativa, sua presença ocorre em adensamentos monoespecíficos inibindo o crescimento de outras espécies características de cada fitofisionomia. Na ESEC-AE o alastramento dessa espécie nos campos, e principalmente nas bordas das veredas, está relacionado ao rebaixamento do lençol freático, consequência da ação antrópica na região (MUNHOZ; RIBEIRO, 2008).

Figura 5. 25. Parcelas (a) 40 e (b) 42 de campo sujo com indivíduos arbóreo-arbustivos influenciando no comportamento espectral.



A parcela de cerrado denso (P16) teve seu valor subestimado em 55%. Essa parcela (Figura 5.26) apresentou o maior valor de AGB observada dentre as parcelas de mesma classe (37,86 t.ha<sup>-1</sup>). Esse alto valor de AGB é decorrente da altura média das árvores (3,14m) e não da área basal (21,07 m<sup>2</sup>.ha<sup>-1</sup>), pois apresenta menor densidade de indivíduos (2390 ind.ha<sup>-1</sup>) e menor diâmetro médio (9,43 cm), se comparada à média de sua classe. Menor área basal significa menor grau de ocupação da área por indivíduos arbóreo-arbustivos (MACHADO; FIGUEIREDO-FILHO, 2009), expondo assim maior porção de solo ou de gramíneas. Esse fator pode ter contribuído para que para as características espectrais dessa parcela diferissem da AGB observada em campo, superestimando seu valor predito.

Figura 5. 26. Parcela 16 (CD). Caracteriza a presença de indivíduos com altura superior à média.



# 5.3.2. Modelagem da AGB com Índices de Vegetação (IVs)

# 5.3.2.1. Análise exploratória IVs

A Tabela 5.8 apresenta os resultados de correlação entre os 22 IVs analisados e a biomassa observada em 45 amostras de campo.

Tabela 5. 8. Coeficiente de correlação de Pearson (r) para as relações entre os índices de vegetação e a Biomassa (AGB) observada em campo. Valores sombreados indicam correlações significativas ao nível de significância de 0,05.

	WBI	VOG	VIG	VARI	SIPI	RVSI	REPI	RENDVI	PSSR	PSRI	PRI	NDWI	NDVI	NDLI	NDII	MSI	MCARI	LWVI2	EVI	C RI1	CAI	ARI
Biomassa	0.33	0.71	0.76	0.76	-0.71	0.20	-0.26	0.79	0.81	-0.77	-0.31	0.42	0.77	-0.33	0.76	-0.34	0.07	0.64	0.78	0.42	0.25	0.66
WBI	1	0.28	0.30	0.32	-0.22	0.33	-0.01	0.37	0.36	-0.27	-0.46	0.36	0.27	-0.26	0.37	-0.21	-0.11	0.21	0.29	0.18	-0.22	0.21
VOG		1	0.80	0.80	-0.84	0.08	-0.17	0.88	0.89	-0.84	-0.42	0.67	0.88	-0.30	0.89	-0.27	0.23	0.72	0.85	0.60	0.24	0.77
VIG			1	0.99	-0.81	0.37	-0.16	0.90	0.91	-0.92	-0.24	0.58	0.86	-0.46	0.84	-0.43	0.01	0.78	0.88	0.44	0.26	0.61
VARI				1	-0.81	0.37	-0.17	0.91	0.92	-0.91	-0.26	0.59	0.87	-0.47	0.85	-0.43	0.02	0.79	0.89	0.45	0.25	0.62
SIPI					1	-0.19	0.31	-0.93	-0.91	0.93	0.26	-0.54	-0.97	0.31	-0.86	0.20	-0.26	-0.80	-0.94	-0.60	-0.30	-0.89
RVSI						1	-0.06	0.36	0.27	-0.31	-0.23	0.06	0.20	-0.34	0.17	-0.10	-0.64	0.27	0.22	-0.13	0.00	0.06
REPI							1	-0.33	-0.31	0.30	0.15	-0.23	-0.34	0.15	-0.34	0.40	-0.11	-0.39	-0.35	-0.22	-0.14	-0.39
RENDVI								1	0.98	-0.95	-0.42	0.67	0.98	-0.43	0.94	-0.34	0.10	0.85	0.97	0.60	0.22	0.86
PSSR									1	-0.93	-0.41	0.68	0.97	-0.45	0.96	-0.35	0.20	0.85	0.96	0.62	0.21	0.85
PSRI										1	0.25	-0.60	-0.94	0.37	-0.88	0.40	-0.11	-0.80	-0.94	-0.51	-0.34	-0.79
PRI											1	-0.59	-0.35	0.00	-0.50	0.18	-0.07	-0.34	-0.32	-0.37	0.12	-0.39
NDWI												1	0.63	-0.17	0.79	-0.40	0.22	0.58	0.63	0.56	0.05	0.56
NDVI													1	-0.36	0.94	-0.26	0.25	0.86	0.98	0.64	0.24	0.91
NDLI														1	-0.37	0.08	-0.05	-0.30	-0.37	-0.31	-0.01	-0.24
NDII															1	-0.36	0.26	0.85	0.93	0.68	0.15	0.85
MSI																1	0.13	-0.32	-0.29	-0.20	-0.16	-0.16
MCARI																	1	0.19	0.24	0.48	0.07	0.32
LWVI2																		1	0.87	0.59	0.12	0.75
EVI																			1	0.63	0.25	0.85
CRI1																				1	0.06	0.65
CAI																					1	0.15
ARI																						1

A relação entre a biomassa e os índices RVSI, REPI, PRI, NDLI, MSI, MCARI e CAI, não foram significativas (p<0,05). As melhores correlações com a biomassa estão associadas aos índices de banda estreita PSSR (r = +0,81) e PSRI (r = -0,77), relacionados com a bioquímica; RENDVI (r = +0,79), relacionado com a fisiologia e o estresse; e EVI (r = +0,78) e NDVI (r = +0,77), relacionados a estrutura da vegetação.

Por meio da Figura 5.27 foi possível compreender a relação entre a biomassa, analisada nas diferentes fitofisionomias, e os índices que melhor se correlacionaram positivamente e negativamente. O aumento da complexidade estrutural das fitofisionomias (dos campos ao cerrado denso) resulta em aumento da biomassa da vegetação. Com o surgimento de indivíduos arbustivos e arbóreos, ocorre formação de dossel, menor exposição de gramíneas (vegetação seca em julho), resultando em aumento da concentração de pigmentos fotossintetizantes como a clorofila (HANSEN, 2003). Esse incremento de clorofila faz com que ocorra maior absorção da radiação na faixa do vermelho, tendendo ao aumento do índice PSSR. Por este motivo, este índice está diretamente relacionado com a biomassa da vegetação.



Figura 5. 27. Relação entre biomassa (AGB) e os índices (a) PSSR, (b) PSRI (p<0,05).

Ao contrário do observado anteriormente, o índice PSRI tende a diminuir com o aumento da biomassa. Ao passo que a vegetação perde biomassa (do cerrado denso aos campos), ocorre aumento da reflectância no vermelho e NIR, causada pela perda de

clorofila e estrutura da vegetação, respectivamente, mantendo baixa reflectância no azul influenciada pela presença de carotenoides (COLE et al, 2014). Esses fatores fazem com que o índice PSRI tenha uma relação linear, porém negativa com a biomassa das fitofisionomias.

#### 5.3.2.2. Modelagem PLSR dos IVs

No modelo PLSR com IVs, PC1 e PC2 explicaram um total de 64% da variância de X e 67% da variância em Y dos dados de calibração. Assim como para o modelo de reflectância, observou-se uma tendência de agrupamento nas amostras de campo limpo para o primeiro fator. Ao passo que os IVs tentam capturar alterações em comprimentos de onda específicos, neste modelo, a amostra P38 (CaL) e P27 (CR) apresentaram comportamento passível de investigação por estar fora dos limites da Elipse de Hotelling T<sup>2</sup> (Figura 5.28).

Figura 5. 28. Distribuição dos escores nos dois primeiros fatores para os dados de calibração do modelo PLSR com índices de vegetação. Valores entre parênteses explicam a variância de X e de Y, respectivamente, em cada fator analisado. Amostras fora da Elipse de Hotelling T<sup>2</sup> apresentaram comportamentos extremos (α = 0,05).



As características que podem ter influenciado o comportamento no gráfico dos escores podem ser mais bem compreendidas quando se analisa o gráfico de *loadings* (Figura 5.29). Valores *loadings* extremos negativos para os índices PSRI e SIPI confirmam a forte relação inversa com a biomassa. Esses índices, relacionados com a perda de pigmentos fotossintetizantes como a clorofila e carotenóides (MERZLYAK et al, 1999;

PENUELAS et al., 1995), influenciaram as amostras que apresentaram baixos valores de biomassa. Valores extremos desses dois índices podem explicar o comportamento detectado pelo teste Hotelling T<sup>2</sup> principalmente para a parcela de campo limpo P38.

Figura 5. 29. Distribuição dos *loadings* nos dois primeiros fatores para os dados de calibração do modelo índices de vegetação. Valores entre parênteses explicam a variância de X e de Y respectivamente, em cada fator analisado.



Diferente do modelo de reflectância, esse modelo que fez uso de 22 IVs como variáveis independentes, necessitou de apenas um fator para maximizar a variância total explicada de Y em 60,31% e minimizar o RMSE em 7,07 t.ha<sup>-1</sup> (Figura 5.30) para os dados de validação.





A variância residual das amostras de campo limpo P34 e P39 atingiram valores acima do limite proposto pelo teste F ( $F_{crit}=1,18$ ; p<0,005), 1,26 e 1,28, respectivamente. Porém, os valores correspondentes a *leverage*, 0,09 (P34) e 0,10 (P39) foram considerados baixos (limite=0,13; p<0,005), demonstrando sua menor influência no modelo (Figura 5.31).

Figura 5. 31. Comparação entre a variância residual de X (limite  $F_{crit} = 1,18$ ) e a *Leverage* (limite = 0,13), verificando a influência de cada amostra na modelagem da AGB pelos 22 índices de vegetação como variáveis independentes X.



Foram ajustados os coeficientes de regressão (B), para cada variável independente (Figura 5.32). Coeficientes com valores extremos (positivos ou negativos) indicam a importância da variável independente no modelo.

Figura 5. 32. Coeficientes ajustados para o modelo PLSR com Índices de vegetação.



A validação do modelo IVs resultou em um R<sup>2</sup> de 0,60 e um RMSE de 7,07 t.ha<sup>-1</sup>, representando 42,3% da média dos valores observados (Figura 5.33). A biomassa predita foi superestimada em 56% das amostras, principalmente para as parcelas de cerrado ralo (CR), campo cerrado (CaC) e campo sujo (CaS).

Figura 5. 33. Valores de AGB observados em relação aos valores preditos na validação cruzada no modelo PLSR com índices de vegetação.



Os maiores erros relativos apresentados pelo modelo foram nas parcelas 42 (CaS) e 32 (CaC), superestimando a AGB em 234% e 250%, respectivamente. Assim como no modelo de reflectância, a parcela 42 (CaS) teve seu valor de biomassa predito superestimado pela presença da espécie *Trembleya parviflora*. Na parcela 32 (CaC), foram observados indícios de queimada, como troncos mortos, sinais de carbonização e rebrotas basais ramificadas (SATO et al., 2010), assim como o surgimento de regeneração induzida pela passagem do fogo (Figura 5.34).

Troncos nessa situação foram amostrados apenas na altura das brotações e as regenerações não foram amostradas por não se enquadrar no nível de inclusão adotado (FELFILI et al., 2005a), resultando em baixa biomassa observada (4,87 t.ha<sup>-1</sup>). No entanto, esse comportamento causado pela passagem do fogo pode ter influenciado nos valores dos IVs, principalmente os relacionados a pigmentos fotossintetizantes.



Figura 5. 34. Parcela de campo cerrado P32 com evidências de queimada.

#### 5.3.3. Modelagem da AGB com razões de bandas

#### 5.3.3.1. Análise exploratória das razões de bandas

As correlações entre todas as possíveis razões das 146 bandas do Hyperion e a biomassa das fitofisionomias estão ilustradas na Figura 5.35. As melhores correlações positivas foram as resultantes da relação IVP/visível, principalmente no vermelho. Essa relação pode ser explicada pelo aumento da concentração de pigmentos fotossintetizantes e o aumento do índice de área foliar (IAF), maior complexidade do dossel, com o incremento de biomassa, resultando em maior absorção da radiação na região do visível, e aumento da reflectância no IVP (ASNER, 2008). Portanto, quanto maior a biomassa da vegetação, maior é a razão IVP/visível. As melhores correlações negativas resultaram da relação vermelho/verde, SWIR 1/IVP e SWIR 2/IVP.


Figura 5. 35. Correlação entre todas as possíveis razões das 146 bandas do Hyperion e a biomassa (AGB).

A região do SWIR relaciona-se com o conteúdo de água na vegetação, e em menor grau, com o conteúdo de nitrogênio, celulose e lignina (ASNER, 2008). Com o incremento de biomassa na vegetação, há aumento na concentração de água vista pelo sensor e no acúmulo de lignina e celulose. O dossel torna-se mais complexo ou estruturado. Esses fatores geram maior absorção da radiação na região do SWIR e maior reflectância na do IVP, resultando em uma relação inversa com a biomassa.

Obteve-se a melhor correlação positiva (r = +0.82) para a razão 1073/691 nm e negativa (r = -0.80) para 1719/1265 nm (Figura 5.36). Ambas as relações foram lineares.

Figura 5. 36. Relação entre biomassa (AGB) e a razão de reflectância (a) 1073/691 nm, (b) 1719/1265 nm (p<0,05).



5.3.3.2. Modelagem PLSR das razões de bandas

No modelo razões de bandas os dois primeiros fatores explicaram um total de 50% da variância de X e 83% da variância em Y dos dados de calibração (Figura 5.37).

Figura 5. 37. Distribuição dos escores nos dois primeiros fatores para os dados de calibração do modelo razões de banda. Valores entre parênteses explicam a variância de X e de Y respectivamente, em cada fator analisado. Amostras fora da Elipse de Hotelling T<sup>2</sup>, apresentam comportamentos extremos (α = 0,05).



Como nos modelos anteriores, a amostra P39 de campo limpo apresentou comportamento passível de investigação por estar fora dos limites da Elipse de Hotelling T<sup>2</sup>. Neste modelo, a grande quantidade de variáveis independentes (10585) não permite verificar, por meio do gráfico de *loadings*, a influência de cada variável X nos escores das amostras. Porém, a análise exploratória, realizada anteriormente, pode ser útil na compreensão da influência das diferentes razões de bandas na relação com as fitofisionomias analisadas.

No ajuste ótimo do modelo razões de bandas foram necessários três fatores para maximizar a variância total explicada de Y em 65,19%, e minimizar o RMSE em 6,63 t.ha<sup>-1</sup> (Figura 5.38) para os dados de validação.

Figura 5. 38. Comportamento da (a) variância explicada de Y, (b) RMSE em cada fator do modelo razões de banda para calibração e validação.



Assim como no modelo reflectância, a amostra P39 (CaL) também exerceu alta influência (Figura 5.39), com *leverage* de 0,38 (limite=0,27; p<0,005). Sua exclusão não se tornou necessária uma vez que sua variância residual (0,67) foi considerada baixa para o modelo ( $F_{crit}$ =1,35; p<0,005).

Figura 5. 39. Comparação entre a variância residual de X (limite F<sub>crit</sub> = 1,35) e a *Leverage* (limite = 0,27), verificando a influência de cada amostra na modelagem da AGB pelas 10585 razões de bandas como variáveis independentes X.



A validação deste modelo resultou em um  $R^2 = 0,65$  e um RMSE = 6,63 t.ha<sup>-1</sup>, representando 39,7% da média dos valores observados de AGB (Figura 5.40).

Figura 5. 40. Valores de AGB observados em relação aos valores preditos na validação cruzada no modelo razões de bandas.



A biomassa predita foi subestimada em 51% das amostras. Assim como observado anteriormente, amostras com valores extremos de biomassa (CD e CaL) não foram bem explicadas pelo modelo, porém os erros relacionados as amostras de CaS foram considerados inferiores aos modelos já ajustados. A parcela P15 de cerrado típico (C) apresentou erro relativo de predição considerado alto, superestimando a AGB em 125%. Apesar do baixo valor de biomassa observado (12,42 t.ha<sup>-1</sup>), a parcela P15 possui densidade de indivíduos (2980 ind.ha<sup>-1</sup>) acima da média (2171 ind.ha<sup>-1</sup>) para esta fitofisionomia (Figura 5.41), principalmente de indivíduos da espécie Pau Santo (*Kielmeyera coriacea*). A alta densidade de indivíduos nessa parcela, tendendo a superestimação de sua ABG.

Figura 5. 41. Parcela P15 (C) com alta densidade de indivíduos principalmente de *Kielmeyera* coriácea.



## 5.3.4. Modelo da AGB com parâmetros de bandas de absorção

### 5.3.4.1. Análise exploratória das bandas de absorção

As correlações entre os parâmetros descritores das bandas de absorção (profundidade, área, largura e assimetria) posicionadas em 680 nm, 980 nm, 1200 nm, 1700 nm, 2100 nm e 2300 nm e a biomassa estão indicadas na Tabela 5.9.

Tabela 5. 9. Coeficiente de correlação (r) para as relações dos parâmetros descritores das bandas de absorção posicionadas em 680 nm, 980 nm, 1200 nm, 1700 nm, 2100 nm e 2300 nm com a biomassa acima do solo (AGB). Os atributos são: P (profundidade da banda), L (largura), Ar (área) e As (assimetria). Valores sombreados indicam correlações significativas ao nível de significância de 0,05.

680nm			980nm 1200nm						1700nm					2100nm				2300nm							
		Р	L	Ar	As	Р	L	Ar	As	Р	L	Ar	As	Р	L	Ar	As	Р	L	Ar	As	Р	L	Ar	As
Biomas	sa	0.78	0.65	0.79	0.20	0.44	0.39	0.42	-0.23	0.16	0.25	0.32	0.09	0.29	0.27	0.23	-0.05	0.29	0.01	0.28	-0.17	0.26	0.16	0.23	0.29
	Р	1	0.89	0.99	0.30	0.61	0.58	0.58	-0.28	0.11	0.24	0.39	0.12	0.32	0.30	0.28	-0.01	0.29	-0.26	0.23	-0.10	0.10	0.02	-0.02	0.09
680nm	L		1	0.90	0.12	0.51	0.47	0.45	-0.27	0.19	0.26	0.44	0.15	0.31	0.33	0.24	0.01	0.26	-0.21	0.20	0.02	0.06	0.05	0.00	0.05
0801111	Ar			1	0.29	0.65	0.61	0.62	-0.29	0.12	0.25	0.41	0.12	0.33	0.32	0.29	-0.02	0.29	-0.26	0.22	-0.06	0.09	0.02	-0.03	0.08
	As				1	0.33	0.37	0.28	-0.09	0.13	-0.03	0.24	0.27	0.01	-0.05	-0.04	-0.07	0.07	-0.14	0.10	-0.06	0.37	0.00	0.01	0.08
	Р					1	0.84	0.93	-0.43	0.00	0.12	0.20	-0.03	0.45	0.35	0.41	-0.08	0.15	-0.30	0.01	0.01	0.20	-0.13	-0.14	-0.18
080nm	L						1	0.89	-0.23	-0.10	-0.01	0.07	-0.16	0.18	0.17	0.17	0.03	0.08	-0.33	0.06	0.05	0.25	0.00	-0.13	-0.13
980mm	Ar							1	-0.36	-0.12	0.11	0.09	-0.09	0.37	0.33	0.40	0.04	0.18	-0.27	0.03	0.08	0.21	-0.12	-0.19	-0.23
	As								1	0.09	-0.17	-0.07	0.10	-0.46	-0.54	-0.45	-0.07	-0.13	0.15	0.09	0.13	-0.16	-0.02	-0.11	0.03
	Р									1	-0.13	0.79	0.36	0.27	0.17	0.32	0.04	0.16	0.19	0.17	0.17	0.00	-0.01	0.05	0.29
1200	L										1	0.26	0.08	0.01	0.03	0.03	-0.05	0.13	-0.03	0.02	-0.01	0.05	-0.17	-0.01	-0.12
120000	Ar											1	0.50	0.28	0.24	0.33	0.04	0.35	0.11	0.32	0.12	-0.06	-0.14	-0.12	0.19
	As												1	0.05	0.13	0.11	0.05	0.22	0.21	0.30	-0.21	-0.14	0.02	-0.05	0.14
	Р													1	0.85	0.83	-0.24	-0.03	-0.04	-0.02	0.11	0.07	-0.05	-0.08	0.11
1700	L														1	0.80	0.02	0.01	0.06	0.11	0.09	-0.04	-0.01	-0.09	0.23
17001111	Ar															1	0.22	0.05	0.01	0.04	0.18	0.09	-0.03	-0.02	0.13
	As																1	0.04	0.18	0.10	0.14	0.05	0.08	0.12	0.01
	Р																	1	0.17	0.68	0.00	-0.19	-0.27	-0.19	0.07
	L																		1	0.53	0.05	0.03	-0.04	0.09	0.13
2100nm	Ar																			1	-0.06	-0.06	-0.13	-0.05	0.19
	As																				1	-0.15	-0.22	-0.22	-0.06
	Р																					1	0.36	0.57	-0.06
	L																						1	0.73	0.17
2300nm	Ar																							1	0.20
	As																								1

Correlações significativas com a biomassa foram obtidas apenas para os parâmetros das bandas posicionadas em 680 nm e 980 nm, associadas à absorção por clorofila e água nas folhas, respectivamente. Os parâmetros em 1200 nm, também associados à absorção por água, e os parâmetros em 1700, 2100 e 2300 nm, associados à absorção por lignina e celulose, não foram considerados significativos. Segundo Galvão et al. (2005), feições espectrais de lignina-celulose tendem a ser mais bem definidas ou ter bandas de absorção mais profundas em espectros de vegetação não-fotossinteticamente ativa, o que não foi consistente com os resultados obtidos. Mesmo após todos os processamentos efetuados nas imagens Hyperion, bandas em comprimentos de onda próximas ao centro da absorção por água e lignina-celulose apresentaram-se bastante ruidosas na data analisada, podendo assim comprometer a caracterização das feições correspondentes.

A profundidade e a área da banda de absorção associada à clorofila (680 nm) apresentaram as melhores correlações com a AGB, produzindo valores r de +0,77 e +0,78, respectivamente (Figura 5.42).

Figura 5. 42. Relação da biomassa (AGB) com (a) profundidade e (b) área da banda de absorção da clorofila em 680 nm (p<0,05).



5.3.4.2. Modelagem PLSR com parâmetros de bandas de absorção

Quando os atributos de bandas de absorção foram testados para a modelagem da AGB com PLSR, os dois primeiros fatores deste modelo explicaram um total de 34% da variância de X e 72% da variância em Y dos dados de calibração. A amostra P5 de cerrado típico (C) foi a única parcela que extrapolou os limites da Elipse de Hotelling T<sup>2</sup> (Figura 5.43).

Figura 5. 43. Distribuição dos escores nos dois primeiros fatores para os dados de calibração do modelo PLSR com parâmetros de bandas de absorção. Valores entre parênteses explicam a variância de X e Y, respectivamente, em cada fator analisado. Amostras fora da Elipse de Hotelling T<sup>2</sup> apresentam comportamentos extremos (α = 0,05).



Por meio do gráfico de *loadings* (Figura 5.44), foi possível perceber a forte influência dos parâmetros da banda de absorção em 680 nm com amostras posicionadas à direita do gráfico, principalmente as parcelas de cerrado denso (CD), cerrado típico (C) e cerrado ralo (CR), ou seja, amostras que possuem maiores valores de biomassa. A forte relação da biomassa (representado em vermelho no gráfico de *loadings*) com parâmetros das feições em 680 nm (representadas em ciano) e 980 nm (representadas em vermelho), foi percebida pela proximidade em seus posicionamentos principalmente no primeiro fator do modelo.

Figura 5. 44. Distribuição dos *loadings* nos dois primeiros fatores para os dados de calibração do modelo parâmetros de bandas de absorção. Valores entre parênteses explicam a variância de X e de Y respectivamente, em cada fator analisado.



Assim como ocorreu no modelo com IVs, apenas um fator foi necessário para maximizar a variância total explicada de Y em 48,58% e minimizar o RMSE em 8,05 t.ha<sup>-1</sup> para os dados de validação (Figura 5.45). Esse modelo apresentou a menor porcentagem de variância explicada e o maior RMSE dentre os modelos analisados, fato este que pode ter forte relação com a baixa correlação entre a biomassa e a maioria dos parâmetros analisados como variáveis independentes.





Quando o gráfico de influências foi analisado, verificou-se que nenhuma amostra, e suas características intrínsecas, exerceu influência significativa no modelo, apresentando resíduos e *leverages* dentro do aceitável (Figura 5.46).

Figura 5. 46. Comparação entre a variância residual de X (limite  $F_{crit} = 1,70$ ) e a *Leverage* (limite = 0,13), indicando a influência de cada amostra na modelagem da AGB pelos 24 parâmetros das seis bandas de absorção selecionadas como variáveis independentes X.



Foram ajustados os coeficientes de regressão (B) para cada uma das 24 variáveis independentes, verificando-se a importância dos atributos da banda de absorção por pigmentos em 680 nm no ajuste do modelo (Figura 5.47).



Figura 5. 47. Coeficientes ajustados para o modelo parâmetros de bandas de absorção.

Para este modelo, foram obtidos R<sup>2</sup> de 0,48 e RMSE de 8,05 t.ha<sup>-1</sup>, representando 48,2% da média dos valores observados de AGB (Figura 5.48). A biomassa predita foi superestimada em 60% das amostras. Diferente do observado anteriormente, 70% das amostras de campo limpo foi superestimado em valores de biomassa. As amostras de cerrado típico e principalmente as de cerrado denso, seguiram o padrão já analisado de subestimativa.

Figura 5. 48. Valores de AGB observados em relação aos valores preditos na validação cruzada do modelo PLSR com parâmetros descritores de bandas de absorção.



A amostra P39 de campo limpo teve seu valor de AGB subestimada em 123%, sendo a única amostra a apresentar valores negativos de biomassa. O solo arenoso e exposto, decorrente da ausência de espécies de gramíneas típicas dessa fitofisionomia e presença da invasora *Trembleya parviflora* (Figura 5.49), fizeram com que a resposta espectral da parcela 39 fosse significativamente diferente. Esse comportamento resultou em baixos valores para os parâmetros de absorção, principalmente para a banda relacionada à

absorção da clorofila em 680 nm, que foi considerada a mais importante para este modelo, resultando em subestimativas de biomassa para a parcela.



Figura 5. 49. Parcela de CaL (P39) dominada pela espécie Trembleya parviflora.

## 5.3.5. Modelagem da AGB com PLSR e todos os atributos

O modelo geral, com todos os atributos, apresentou resultados semelhantes ao modelo PLSR com razões de bandas em todas as etapas. O elevado número de razões de bandas (10585 razões) fez com que o conjunto de variáveis X em questão dominasse o comportamento do modelo, tendendo a um ajuste muito similar. Os resultados de escores e influências foram os mesmos do modelo gerado com reflectância, confirmando a grande influência desse conjunto de variáveis independentes do ajuste do modelo.

Mesmo com o domínio das razões de bandas, a entrada dos conjuntos reflectância, IVs e parâmetros de bandas de absorção resultaram em pequeno acréscimo na variância explicada de Y em 0,23% (65,42%) e um decréscimo do RMSE em 0,18% (6,60 t.ha<sup>-1</sup>) (Figura 5.50).

Figura 5. 50. Comportamento da (a) variância explicada de Y, (b) RMSE em cada fator do modelo geral para calibração e validação cruzada.



Assim como no modelo razões de bandas, ocorreu a subestimativa dos resultados em 51% das amostras. Porém, o  $R^2$  de 0,66 e RMSE de 6,60 t.ha<sup>-1</sup> foram resultantes do melhor ajuste para as amostras de C, CR e CaC (Figura 5.51).

Figura 5. 51. Valores de AGB observados em relação aos valores preditos na validação cruzada do modelo PLSR com o conjunto total de atributos (reflectância, razões de reflectância, IVs e parâmetros descritores de seis bandas de absorção).



A comparação do desempenho dos modelos específicos e geral pode ser vista na Tabela 5.10. Segundo Kooistra et al. (2004), para considerar um modelo mais preciso do que outro, o RMSE deve ser reduzido em pelo menos 2%. Tendo como base o modelo de reflectância, pois este não sofreu nenhum tipo de transformação, os modelos com IVs e parâmetros descritores das bandas de absorção atingiram resultados inferiores aos demais modelos. Mesmo necessitando de apenas um fator (PC) para a modelagem, as transformações do espectro para esses dois conjuntos de variáveis geraram um aumento do RMSE em 2,3% no modelo com IVs e de 8,2% no modelo com parâmetros de bandas de absorção. Esses resultados podem ser explicados pela baixa correlação entre a biomassa observada e algumas das variáveis analisadas dentro desses dois conjuntos de dados. Ocorreu uma redução do RMSE e incremento no R<sup>2</sup> nos modelos com razões de bandas. Porém, em geral, com base no critério mencionado acima, a melhora não atingiu 2% de redução do RMSE. O grande número de variáveis independentes do modelo geral, oriundas do conjunto razões de bandas, resultou em valores muito similares de R<sup>2</sup> e RMSE. Em resumo, dentre os modelos PLSR específicos, os de reflectância e razões de reflectância mostraram os maiores valores de R<sup>2</sup> e os menores valores de RMSE, com o pior desempenho sendo observado para o modelo com parâmetros descritores das bandas de absorção (Tabela 5.10). O modelo Geral com todos os atributos mostrou um pequeno ganho na estimativa de AGB quando comparado com os modelos específicos de reflectância ou razões de reflectância.

Modelo	N° de Fatores	R <sup>2</sup>	RMSE (t.ha <sup>-1</sup> )
Reflectância	4	0,64	6,72
Índices de Vegetação	1	0,60	7,07
Razões de banda	3	0,65	6,63
Parâmetros de bandas de absorção	1	0,48	8,05
Geral	3	0,66	6,60

Tabela 5. 10. Desempenho dos modelos PLSR específicos e geral na predição da AGB das fitofisionomias do Cerrado.

Estudos em diferentes formações vegetais confirmam o potencial da regressão PLSR na estimativa de biomassa utilizando dados hiperespectrais (CHO et al., 2007; CLEVER et al., 2007; HANSEN; SCHJOERRING, 2003; MAREBEL; ALVAREZ-TABOADA, 2013; VYAS; KRISHNAYYA, 2014). No presente estudo, o modelo reflectância

demonstrou superioridade no ajuste por PLSR (RMSE =  $6,72 \text{ t.ha}^{-1}$ ) em comparação ao ajuste por regressão linear simples com bandas individuais (RMSE =  $7,24 \text{ t.ha}^{-1}$ ), resultando em redução do RMSE em 3,1 %. No entanto, para os modelos IVs, razões de bandas e parâmetros de bandas de absorção, o ajuste de parâmetros individuais apresentou melhores resultados com relação a modelagem PLSR, resultados contrários aos encontrados por Cho et al. (2007) e Marabel e Alvarez-Taboada (2013).

Os erros de ajuste obtidos neste estudo são compatíveis com os reportados por Laurin et al. (2014), ao estudarem uma floresta tropical Africana. No presente estudo, há várias fontes de incerteza que afetam os resultados, incluindo: erros inerentes introduzidos pela equação alométrica de estimativa de biomassa; erros de calibração da modelagem da AGB em 2015 com dados hiperespectrais de 2014 e erros de mensuração de parâmetros biofísicos realizados em campo. Esses erros, juntamente com os erros causados pela correção geométrica e radiométrica dos dados de sensoriamento remoto, são fontes conhecidas de incerteza na análise de dados de sensoriamento remoto (LU et al., 2012). Uma possibilidade de melhoria nas estimativas de biomassa para esse estudo e que vem ganhando espaço na literatura é a fusão entre dados hiperespectrais e LiDAR. Os dados LiDAR expressam com maior acurácia as mensurações de certos parâmetros biofísicos da vegetação e sua fusão com dados hiperespectrais vem se mostrando promissora em estudos de biomassa em diferentes tipologias vegetais (ANDERSON et al., 2008; CHEN, 2013; CLARK et al, 2011; LATIFI et al., 2015; LAURIN et al., 2014; SWATANTRAN et al., 2011).

# 6. CONCLUSÕES E RECOMENDAÇÕES

Os resultados desse trabalho demonstraram que a análise dos atributos hiperespectrais proporcionou o detalhamento do comportamento espectro-sazonal de cada fitofisionomia presente na Estação Ecológica de Águas Emendadas (ESEC-AE). Analisados isoladamente, através dos conjuntos de atributos, ou de maneira geral com a reunião de todos eles, essas abordagens fizeram com que o objetivo central desse estudo fosse atingido, obtendo êxito na caracterização, na discriminação e na modelagem do gradiente de vegetação de fitofisionomias do Cerrado.

Na análise florístico-estrutural observaram-se um total de 6.407 árvores, distribuídas em 34 famílias e 76 espécies com características intrínsecas a cada fitofisionomia, apresentando diversidade e parâmetros estruturais próximos àqueles relatados na literatura. A subdivisão das fitofisionomias savânicas (CD, C, CR, CaC), teve o intuito de conter toda a densidade da vegetação presente na ESEC-AE, estratégia importante principalmente no aspecto espectral. Os parâmetros estruturais, como diâmetro e altura, permitiram expressar um gradiente entre as fitofisionomias, porém não demonstrando diferenças altamente significativas em valores médios. A biomassa apresentou valores médios que variaram de  $34,46\pm2,7$  t.ha<sup>-1</sup> em parcelas de cerrado denso a  $3,98\pm0,7$  t.ha<sup>-1</sup> em parcelas de campo limpo. Os valores de AGB média não diferiram significativamente entre as fitofisionomias campestres (CaS e CaL), assim como ocorreu com os valores médios de AGB entre CR e CaC.

A caracterização espectro-sazonal por meio de índices de vegetação e parâmetros de bandas de absorção sugere maior separabilidade entre fitofisionomias no período seco. Contudo, quando analisado através da reflectância de bandas isoladas, o período chuvoso demonstrou alta separabilidade entre fitofisionomias em bandas situadas no visível, principalmente no vermelho (680 nm). Já no período seco, usando essa mesma abordagem, o intervalo de maior separabilidade foi a região do SWIR 1 (1648 nm).

A discriminação por MDA apresentou melhores resultados na análise geral dos atributos quando aplicada no período seco, confirmando a tendência observada na caracterização espectral das fitofisionomias. O ganho em 2,8% na acurácia do período chuvoso para o seco foi considerado significativo de acordo com o teste Z (p<0,01), com valores do

índice Kappa foram de 0,78 e 0,82 para o período chuvoso e seco respectivamente. Os maiores ganhos na acurácia entre períodos foram observados nas fitofisionomias cerrado típico e campo limpo ao longo dos conjuntos de atributos avaliados. Autores afirmam que no período seco sensores orbitais capturam de forma mais eficiente as diferenças estruturais na vegetação. Já no período chuvoso a resposta da vegetação pode se confundir pela maior interferência do dossel, mais vigoroso nessa época.

O uso de dados do sensor hiperespectral Hyperion viabilizou a combinação de diferentes métricas na modelagem da AGB das fitofisionomias do Cerrado, possibilitando a compreensão da importância isolada e combinada dos diferentes atributos hiperespectrais como dados de entrada nos modelos PLSR. Os melhores resultados de estimativa de AGB foram encontrados para a modelagem geral, modelo que reuniu todos os atributos das análises anteriores (reflectância, IVs, razões de bandas e parâmetros de bandas de absorção), resultando em R<sup>2</sup> de 0,66 e RMSE de 6,60 t.ha<sup>-1</sup>. Esses valores foram próximos aos encontrados na modelagem por razões de bandas (R<sup>2</sup> = 0,65 e RMSE = 6,63 t.ha<sup>-1</sup>), possivelmente pelo alto número de atributos oriundos desse conjunto de métricas (10585 razões). O comportamento anômalo de algumas parcelas, com relação à estimativa de AGB, foi investigado e constatou-se que, a presença de espécies invasoras, exposição do solo em maior ou menor grau, assim como indícios de queimada, podem ter influenciado em seus elevados erros de estimativa. Essas características foram frequentemente observadas na ESEC-AE, confirmando as dificuldades de estimativas de parâmetros biofísicos em Cerrados, já relatadas por diferentes autores. Essa gama de atributos e possibilidades fornecidas a partir de dados hiperespectrais, podem embasar o desenvolvimento de estudos, principalmente no bioma Cerrado, com os futuros sensores hiperespectrais, HyspIRI e EnMAP. Esses sensores irão operar em faixas de imageamento mais amplas e com melhor relação sinal ruído, possibilitando maior acurácia nas análises.

Uma possibilidade de melhoria na modelagem de parâmetros biofísicos em diferentes formações vegetais, e que vem ganhando espaço na atualidade, é a utilização de métricas derivadas de dados LiDAR. Estas métricas, analisadas juntamente com dados hiperespectrais, podem proporcionar uma maior acurácia na modelagem da estrutura do gradiente de vegetação e, por conseguinte, melhorar os níveis de informações espaciais sobretudo, do teor de emissão e reabsorção de carbono nos domínios dos Cerrados.

# **REFERÊNCIAS BIBLIOGRÁFICAS**

ABDI, H. Partial least square regression pls-regression. Encyclopedia of Measuremen and Statistics, p. 1–13, 2007.

ALBUQUERQUE, L. G. Histórico: criação da unidade de conservação. In: FONSECA, F. O. (Org.). Águas emendadas . 1 ed. Brasília, DF: SEDUMA, 2008. cap. II-II.4, p. 38-40.

ANDERSON, J.; PLOURDE, L.; MARTIN, M.; BRASWELL, B.; SMITH, M.; DUBAYAH, R.; HOFTON, M.; BLAIR, J. Integrating waveform lidar with hyperspectral imagery for inventory of a northern temperate forest. **Remote Sensing of Environment**, v. 112, n. 4, p. 1856–1870, 2008.

ANDRADE, L. A. Z.; FELFILI, J. M.; VIOLATTI, L. Fitossociologia de uma área de cerrado denso na recor-ibge, brasília-df. **Acta Botanica Brasilica**, v. 16, n. 2, p. 225–40, 2002.

APAN, A.; HELD, A.; PHINN, S.; MARKLEY, J. Detecting sugarcane 'orange rust' disease using EO-1 Hyperion hyperspectral imagery. **International Journal of Remote Sensing**, v.25, n. 2, p. 489-498, 2004.

ASNER, G.P. Hyperspectral remote sensing of canopy chemistry, physiology, and biodiversity in tropical rain forests. In: KALACSKA, M; SANCHEZ-AZOFEIFA G. A. (Eds). **Hyperspectral remote sensing of tropical and sub-tropical forests**. Taylor and Francis Group - CRC Press, 2008. Chapter 12, p. 261-296.

ASNER, G. P.; MARTIN, R. E. Spectral and chemical analysis of tropical forests: scaling from leaf to canopy levels. **Remote Sensing of Environment**, v. 112, n. 10, p. 3958–3970, 2008.

ASSUNÇÃO, S. L.; FELFILI, J. M. Fitossociologia de um fragmento de cerrado sensu stricto na apa do paranoá, df, brasil. Acta Botanica Brasilica, v. 18, n. 4, p. 903–909, 2004.

BLACKBURN, G. A. Spectral indices for estimating photosynthetic pigment concentrations: a test using senescent tree leaves. **International Journal of Remote Sensing**, v. 19, p. 657–675, 1998.

BÖHM, K.; SMIDT, E.; TINTNER, J.; FREITAS, L. Application of multivariate data analyses in waste management. **Multivariate Analysis in Management, Engineering and the Sciences**, 2012.

BRAGA, F. A.; BARROS, N. F.; SOUZA, A. L. e COSTA, L. M.. Características ambientais determinantes da capacidade produtiva de sítios cultivados com eucalipto. **Revista Brasileira de Ciências do Solo**, v. 23, n.2, p. 291-298, 1999.

BREUNIG, F.M.; GALVÃO, L.S.; FORMAGGIO, A.R.; EPIPHANIO, J.C.N. Directional effects on NDVI and LAI retrievals from MODIS: A case study in Brazil with soybean. **International Journal of Applied Earth Observation and Geoinformation**, v. 13, n. 1, p. 34-42, 2011. CAMO Technologies Inc. **Manual software Unscrambler® X 10.2**. 2013. Disponível em: <a href="http://www.camo.com/downloads/user-manuals.html">http://www.camo.com/downloads/user-manuals.html</a>. Acesso em 20 nov. 2015.

CARVALHO, A. P. F.; BUSTAMANTE, M. M. 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. 17-25, 2007.

CARVALHO, R. D. Meio físico: localização da unidade. In: FONSECA, F. O. (Org.). Águas Emendadas . 1 ed. Brasília, DF: SEDUMA, 2008. cap. V-V.1, p. 95-100.

CHEN, Q. Lidar remote sensing of vegetation biomass. In: WENG, Q.; WANG, G. (Eds.), **Remote Sensing of Natural Resources**, CRC Press: Taylor & Francis, Group, 2013. p. 399–420.

CHEN, Q.; VAGLIO LAURIN, G.; BATTLES, J. J.; SAAH, D. Integration of airborne lidar and vegetation types derived from aerial photography for mapping aboveground live biomass. **Remote Sensing of Environment**, v. 121, p. 108–117, 2012.

CHO, M. A.; SKIDMORE, A.; CORSI, F.; VAN WIEREN, S. E.; SOBHAN, I. Estimation of green grass/herb biomass from airborne hyperspectral imagery using spectral indices and partial least squares regression. **International Journal of Applied Earth Observation and Geoinformation**, v. 9, n. 4, p. 414–424, 2007.

CHRISTIAN, B.; JOSHI, N.; SAINI, M.; MEHTA, N.; GOROSHI, S.; NIDAMANURI, R. R.; THENKABAIL, P.; DESAI, A. R.; KRISHNAYYA, N. S. R. Seasonal variations in phenology and productivity of a tropical dry deciduous forest from modis and hyperion. **Agricultural and Forest Meteorology**, v. 214-215, p. 91 -105, 2015.

CLARK, M. L.; ROBERTS, D. A.; EWEL, J. J.; CLARK, D. B. Estimation of tropical rain forest aboveground biomass with small-footprint lidar and hyperspectral sensors. **Remote Sensing of Environment**, v. 115, n. 11, p. 2931–2942, 2011.

CLARK, R. N.; ROUSH, T. L. Reflectance spectroscopy: quantitative analysis techniques for remote sensing applications. Journal of Geophysical Research, v. 89, n. 7, p. 6329-6340, 1984.

CLEVERS, J. G. P. W.; VAN DER HEIJDEN, G. W. A. M.; VERZAKOV, S.; SCHAEPMAN, M. E. Estimating grassland biomass using svm band shaving of hyperspectral data. **Photogrammetric Engineering and Remote Sensing**, v. 73, n. 9, p. 1141–1148, 2007.

COLE, B.; MCMORROW, J.; EVANS, M. Spectral monitoring of moorland plant phenology to identify a temporal window for hyperspectral remote sensing of peatland. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 90, p. 49–58, 2014.

COLWELL, R. K.; MAO, C. X.; CHANG, J. Interpolando, extrapolando y comparando las curvas de acumalación de especies basada en su incidencia. **Ecology**, v. 85, n. 10, p. 2717–2727, 2004.

CONGALTON, R. G.; MEAD, R. A. A quantitative method to test for consistency and correctness in photointerpretation. **Photogrammetric Engineering and Remote Sensing**, v.49, n.1, p.69-74, 1983.

COOLEY, W.W.; LOHNES, P.R. Multivariate data analysis. New York: John Wiley, 1971. 364p.

DAUGHTRY, C. S. T. 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.

EFRON, B.; GONG, G. A leisurely look at the bootstrap, the jackknife, and crossvalidation. **The American Statistician**, v. 37, n. 1, p. 36-48, 1983.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUARIA (EMBRAPA). Levantamento de reconhecimento dos solos do Distrito Federal. Rio de Janeiro, Boletim Tecnico n. 53, EMBRAPA-SNLCS, 1978. 455 p.

EXELIS. ENVI versão 5.0. Boulder: Exelis Visual Information Solutions, 2013.

FÁVERO, L. P.; BELFIORE, P.; SILVA, F.L.; CHAN, B.L. **Análise de dados:** modelagem multivariada para tomada de decisões. Rio de Janeiro: Campus/Elsevier, 2009, 646 p.

FELDE, G. W.; ANDERSON, G. P.; COOLEY, T. W.; MATTHEW, M. W.; ADLER-GOLDEN, S. M.; BERK, A.; LEE, J. Analysis of hyperion data with the flash atmospheric correction algorithm. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS'03), Toulouse, France. **Proceedings...** Toulouse: IEEE, 2003. v. 1, p. 90–92.

FELFILI, J. M.; CARVALHO, F.A.; HAIDAR, R.F. Manual para o monitoramento de parcelas permanentes nos biomas Cerrado e Pantanal. Brasília: EdUnB, 2005a. 55p. (ISBN 85 – 87599).

FELFILI, J. M.; FILGUEIRAS, T.S.; HARIDASAN, M.; SILVA-JÚNIOR, M.C.; MENDONÇA, R.; REZENDE, A.V.Projeto biogeografia dobioma Cerrado: vegetação e solos. **Caderno de Geociências do IBGE**, n. 12, p. 75-166, 1994.

FELFILI, J. M.; SEVILHA, A. C.; SILVA-JÚNIOR, M. C. Comparação entre as unidades fisiográficas da Chapada Pratinha, Veadeiros e Espigão Mestre do São Francisco. In: FELFILI, J.M.; SILVA-JÚNIOR (Org.). **Biogeografia do bioma Cerrado**: estudo fitofisionômico na Chapada do Espigão Mestre do São Francisco. Brasília: UnB, 2001, 80-94 p.

FELFILI, J. M.; SILVA JÚNIOR., M. C. A comparative study of cerrado (sensu stricto) vegetation in Central Brazil. Journal of Tropical Ecology, v. 9, p. 277-289, 1993.

FELFILI, J. M.; SILVA JÚNIOR, M. C.; MENDONÇA, R. C.; FAGG, C. W.; FILGUEIRAS, T. S.; MECENAS, V. V. Vegetação e Flora: Fitofisionomias e Flora. In: Fonseca, F. O. (Org.). Águas Emendadas . 1 ed. Brasília: SEDUMA, 2008. cap. VI-V.2, p. 152-155.

FELFILI, J. M.; SILVA-JÚNIOR, M. C.; REZENDE, A. V.; MACHADO, J. W. B.; WALTER, B. M. T., SILVA, P. E. N.; HAY, J. D. Análise comparativa da florística e fitossociologia da vegetação arbórea do Cerrado sentido restrito na Chapada Pratinha, DF- Brasil. Acta Botânica Brasílica, v.2, n. 6, p. 27-46, 1992.

FELFILI, J. M.; SOUSA-SILVA, J. C.; SCARIOT, A. Biodiversidade, ecologia e conservação do Cerrado: avanços no conhecimento. In: SCARIOT, A.; SOUSA-SILVA, J.C.; FELFILI, J.M. (Org). Cerrado: ecologia, biodiversidade e conservação. Brasília: Ministério do Meio Ambiente, 2005b. 439 p.

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

FERREIRA, J. N. Padrões de estrutura e diversidade da vegetação lenhosa relacionados à heterogeneidade espacial de água no solo em cerrado do Brasil Central. 2006. 130 p. Tese (Doutorado em Ecologia) - Universidade de Brasília (UnB), Brasília, 2006.

FERREIRA, L. G.; ASNER, G. P.; KNAPP, D. E.; DAVIDSON, E. A.; COE, M.; BUSTAMANTE, M. M. C.; DE OLIVEIRA, E. L. Equivalent water thickness in savanna ecosystems: modis estimates based on ground and eo-1 hyperion data. **International Journal of Remote Sensing**, v. 32, n. 22 p. 7423–7440, 2011.

FERREIRA, L.G.; YOSHIOKA, H.; HUETE, A.; SANO, E.E. Optical characterization of the Brazilian savanna physiognomies for improved land cover monitoring of the Cerrado biome: preliminary assessments from an airborne campaign over an LBA core site. **Journal of Arid Environments**, v. 56, n. 3, p. 425-447, 2004.

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.

FIELD, C. B. Primary production of the biosphere: integrating terrestrial and oceanic components. **Science**, v. 281, n. 5374, p. 237–240, 1998.

FURLEY, P. A. Tropical savannas and associated forests: vegetation and plant ecology. **Progress in Physical Geography**, v. 31, n. 2, p. 203–211, 2007.

GALVÃO, L.S.; BREUNIG, F. M.; SANTOS, J.R.; MOURA, Y. M. View-illumination effects on hyperspectral vegetation indices in the Amazonian tropical forest. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 291-300, 2013.

GALVÃO, L. S.; DOS SANTOS, J. R.; ROBERTS, D. A.; BREUNIG, F. M.; TOOMEY, M.; DE MOURA, Y. M. On intra-annual evi variability in the dry season of tropical forest: a case study with modis and hyperspectral data. **Remote Sensing of Environment**, v. 115, p. 2350–2359, 2011. 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. Possibilities of discriminating tropical secondary succession in amazônia using hyperspectral and multiangular chris/proba data. International Journal of Applied Earth Observation and Geoinformation, v. 11, p. 8–14, 2009a.

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. **Remote Sensing of Environment**, v. 113, p. 846–856, 2009b.

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, p. 492-501, 1997.

GAO, B. 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.

GELADI, P.; KOWALSKI, B. R. Partial least-squares regression: A tutorial. Analytical Chimica Acta, v. 185, p. 1-17, 1986.

GEO LÓGICA/ECOTECH. **Plano de manejo**: programa de proteção, planejamento e gestão para a Estação Ecológica de Águas Emendadas (ESEC-AE). Brasília, 2009.

GITELSON, A. A.; KAUFMAN, Y. J.; STARK, R.; RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v. 80, n. 1, p. 76–87, 2002a.

GITELSON, A. A.; 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.; MERZLYAK, M. N.; LICHTENTHALER, H. K. Detection of red edge position and chlorophyll content by reflectance measurements near 700 nm. **Journal of Plant Physiology**, p. 148, n 3–4, p. 501–508, 1996.

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

GONÇALVES, F. G.; SANTOS, J. R. Composição florística e estrutura de uma unidade de manejo florestal sustentável na Floresta Nacional do Tapajós, Pará. Acta Amazonica, v. 38, n. 2, p. 229–244, 2008.

GREEN, A. A.; BERMAN, M.; SWITZER, P.;CRAIG, M. D. A transformation for ordering multispectral data in terms of image quality with implications for noise removal. **IEEE Transactions on Geoscience and Remote Sensing**, v.26, n. 1, p. 65-74, 1988.

GUANTER, L.; KAUFMANN, H.; SEGL, K.; FOERSTER, S.; ROGASS, C.; CHABRILLAT, S.; KÜSTER, T.; HOLLSTEIN, A.; ROSSNER, G.; CHLEBEK, C.; STRAIF, C.; FISCHER, S.; SCHRADER, S.; STORCH, T.; HEIDEN, U.; MUELLER, A.; BACHMANN, M.; MÜHLE, H.; MÜLLER, R.; HABERMEYER, M.; OHNDORF, A.; HILL, J.; BUDDENBAUM, H.; HOSTERT, P.; VAN DER LINDEN, S.; LEITÃO, P.; RABE, A.; DOERFFER, R.; KRASEMANN, H.; XI, H.; MAUSER, W.; HANK, T.; LOCHERER, M.; RAST, M.; STAENZ, K.; SANG, B. Monitoring natural ecosystem and ecological gradients: perspectives with EnMAP. **Remote Sensing**, v. 7, n. 10, p. 13098–13119, 2015.

HAIR, J.F.; ANDERSON, R.E.; TATHAM, R.L.; BLACK, W.C. Análise multivariada de dados. 5. ed. Porto Alegre, RS: Bookman, 2005, 593 p.

HANSEN, P. M.; SCHJOERRING, J. K. Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. **Remote sensing of environment**, v. 86, n. 4, p. 542–553, 2003.

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

HOROWITZ, C.; JESUS, F. Estação Ecológica de Águas Emendadas: O sistema de Unidades de Conservação no Brasil. In: Fonseca, F. O. (Org.). Águas Emendadas. 1 ed. Brasília: SEDUMA, 2008. cap. III-III.2, p. 48-48.

HUBERT, M.; VANDEN BRANDEN, K. Robust Methods for Partial Least Squares Regression. Journal of Chemometrics, v. 17, p. 537–549, 2003.

HUBERTY, C. J. Issues in the use and interpretation of discriminant analysis. **Psychological Bulletin**, v. 95, n. 1, p. 156–171, 1984.

HUETE, A.R.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83 n. 1–2, p. 195–213, 2002.

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

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

JENSEN, J. R. **Remote sensing of the environment**: an earth resource perspective. 2. ed. Upper Saddle River, NJ: Prentice Hall, 2007. 592 p.

JOHNSON, R.A., WICHERN, D.W. Applied multivariate statistical analysis. New Jersey: Prentice Hall, 1988. 607p.

KAUFFMAN, J.B.; CUMMINGS, D.L.; WARD, D.E. Relationships of fire, biomass and nutrient dynamics along a vegetation gradient in the Brazilian Cerrado. **The Journal of Ecology**, v. 82, p. 519-531, 1994.

KOKALY, R.F. **PRISM**: processing routines in IDL for spectroscopic measurements (installation manual and user's guied, version 1.0). U.S. Geological Survey Open-File Report 2011–1155, 432p. Disponível em <a href="http://pubs.usgs.gov/of/2011/1155/">http://pubs.usgs.gov/of/2011/1155/</a>. Acesso em 20 set. 2015.

KOKALY, R. F.; SKIDMORE, A. K. Plant phenolics and absorption features in vegetation reflectance spectra near 1.66µm. International Journal of Applied Earth Observations and Geoinformation, v. 43, p. 1–29, 2015.

KOOISTRA, L.; SALAS, E. A. .; CLEVERS, J. G. P. .; WEHRENS, R.; LEUVEN, R. S. E. .; NIENHUIS, P. .; BUYDENS, L. M. . Exploring field vegetation reflectance as an indicator of soil contamination in river floodplains. **Environmental Pollution**, v. 127, n. 2, p. 281–290, 2004.

LACERDA, M. P. C. Meio físico: solos. In: FONSECA, F. O. (Org.). Águas Emendadas . 1 ed. Brasília: SEDUMA, 2008. cap. V-V.5, p. 140-147.

LACERDA, M. P. C.; BARBOSA, I. O. Relações Pedomorfogeológicas e Distribuição de Pedoformas na Estação Ecológica de águas Emendadas, Distrito Federal. **Revista Brasileira de Ciência do Solo**, v.36, p.709-721. 2012.

LATIFI, H.; FASSNACHT, F. E.; HARTIG, F.; BERGER, C.; HERNÁNDEZ, J.; CORVALÁN, P.; KOCH, B. Stratified aboveground forest biomass estimation by remote sensing data. International Journal of Applied Earth Observation and Geoinformation, v. 38, p. 229–241, 2015.

LAURIN, G. V.; CHEN, Q.; LINDSELL, J. A.; COOMES, D. A.; FRATE, F. D.; GUERRIERO, L.; PIROTTI, F.; VALENTINI, R. Above ground biomass estimation in an African tropical forest with lidar and hyperspectral data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.89, p. 49–58, 2014.

LEI, C. L.; JU, C. Y.; CAI, T. J.; JING, X.; WEI, X. H.; DI, X. Y. Estimating canopy closure density and above-ground tree biomass using partial least square methods in chinese boreal forests. **Journal of Forestry Research**, v. 23, p. 191–196, 2012.

LEITÃO, P. J.; SCHWIEDER, M.; SUESS, S.; OKUJENI, A.; GALVÃO, L. S.; VAN DER LINDEN, S.; HOSTERT, P. Monitoring natural ecosystem and ecological gradients: perspectives with EnMAP. **Remote Sensing**, v. 7, n. 10, p. 13098–13119, 2015.

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, p. 276–286, 2007.

LIU, D.; GUO, W. Identification of kiwifruits treated with exogenous plant growth regulator using near-infrared hyperspectral reflectance imaging. Food Analytical Methods, v. 8, p. 164–172, 2014.

MACHADO, S. A.; FIGUEIREDO FILHO, A. **Dendrometria**. 2. ed. Guarapuava: Unicentro, 2006. 316 p.

MAGURRAN, A. E. Ecological Diversity and its measurement. Princeton: Princeton University Press, 1988. 179 p.

MAIA, J. M. F. Estação Ecológica de Águas Emendadas: vocação para a pesquisa. In: FONSECA, F. O. (Org.). Águas Emendadas . 1 ed. Brasília: SEDUMA, 2008. cap. III-III.5, p. 55-74.

MAIA, J. M. F.; BAPTISTA, G. M. M. Meio físico: clima. In: FONSECA, F. O. (Org.). Águas Emendadas. 1 ed. Brasília: SEDUMA, 2008. cap. V-V.2, p. 101-109.

MARABEL, M.; ALVAREZ-TABOADA, F. Spectroscopic determination of aboveground biomass in grasslands using spectral transformations, support vector machine and partial least squares regression. **Sensors**, v. 13, n. 8, p. 10027–51, 2013.

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, 8, 9-11 February, 1999, Pasadena, USA. **Proceedings...** Pasadena: JPL Publication 99-17, p. 299-307, 1999.

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.

MEYER, J. Y. Observation on the reproductive biology of Miconia calvescens DC. (Melastomataceae), an alien invasive tree on an island of Tahiti (South Pacific Ocean). **Biotropica**, v. 30, p. 609-624, 1998.

MILLÁN, V. E. G.; AZOFEIFA, A. S; GARCÍA G. C. M.; RIVARD, B. Quantifying tropical dry forest succession in the Americas using CHRIS/PROBA. Remote Sensing of Environment. v.144, p. 120–136, 2014.

MIRANDA, S. C. Variação espacial e temporal da biomassa vegetal em áreas de Cerrado. 2012. 142p. Tese de Doutorado (Doutorado em Ecologia) - Universidade de Brasília, Brasília, DF, 2012.

MIURA, T.; HUETE, A. R.; FERREIRA, L. G.; SANO, E. E. Discrimination and biophysical characterization of Cerrado physiognomies with EO-1 hyperspectral Hyperion. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003. Belo Horizonte. **Anais...** São José dos Campos: INPE, 2003. p. 1077-1082. Disponível em:<<u>http://urlib.net/ltid.inpe.br/sbsr/2002/11.17.01.11</u>>. Acesso em: 10 out. 2015.

MORENO, M. I. C.; SCHIAVINI, I.; HARIDASAN, M. Fatores edáficos influenciando na estrutura de fitofisionomias do Cerrado. **Caminhos de Geografia**, v. 9, n. 25, p. 173-194, 2008.

MOURA, Y. M.; GALVÃO, L. S.; DOS SANTOS, J. R.; ROBERTS, D. A.; BREUNIG, F. M. Use of misr/terra data to study intra- and inter-annual evi variations in the dry season of tropical forest. **Remote Sensing of Environment**, v. 127, p. 260–270, 2012. MUELLER-DOMBOIS, D.; ELLEMBERG, H. Aims and methods vegetation ecology. New York: Wiley, 1974. 547 p.

MUNHOZ, C. B. R.; RIBEIRO, J. F. Vegetação e flora: veredas. In: FONSECA, F. O. (Org.). Águas Emendadas. 1 ed. Brasília: SEDUMA, 2008. cap. VI.3, p. 156-162.

MYERS, N.; MITTERMEYER, R.A.; MITTERMEYER, C.G.; FONSECA, G.A.; KENT, J. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. 6772, p. 853–858, 2000.

OLIVEIRA FILHO, A.T.; RATTER, J.A. Vegetation physiognomies and woody flora of the cerrado biome. In: OLIVEIRA P. S.; MARQUIS R. J. (Ed). **The cerrados of Brazil.** New York: Columbia University Press, 2002. p.91-120.

OTTMAR, R. D.; VIHNANEK, R. E.; MIRANDA, H.S.; SATO, M.N.; ANDRADE, S.M.A. Séries de estereo-fotografias para quantificar a biomassa da vegetação do Cerrado do Brasil Central – volume I. Gen. Tech. Rep. PNW-GTR-519. Portland, OR:U.S. Department of Agriculture, Forest Service, Pacific Northwest Research Station. 2001. 87p.

PALHARES, D.; FRANCO, A. C.; ZAIDAN, L. B. P. Respostas fotossintéticas de plantas do cerrado nas estações seca e chuvosa. **Revista Brasileira de Biociências**, v. 8, n. 2, p. 213-220, 2010.

PAPES, M.; TUPAYACHI, R.; MARTINEZ, P.; PETERSON, A. T.; ASNER, G. P.; POWELL, G. V. N. Seasonal variation in spectral signatures of five genera of rainforest trees. Ieee Journal of Selected Topics in Applied Earth Observations and Remote Sensing, v. 6, n. 2, p. 339–350, 2013.

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

PEERBHAY, K. Y.; MUTANGA, O.; ISMAIL, R. Commercial tree species discrimination using airborne aisa eagle hyperspectral imagery and partial least squares discriminant analysis (pls-da) in kwazulu-natal, south africa. **Isprs Journal of Photogrammetry and Remote Sensing**, v. 79, p. 19–28, 2013.

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

PEÑUELAS, J.; PINOL, J.; OGAYA, R.; LILELLA. I., Estimation of plant water content by the reflectance water index WI (R900/R970).**International Journal of Remote Sensing**, v. 18, p. 2869–2875, 1997.

PESTANA, M. H.; GAJEIRO, J. N. Análise de dados para ciências sociais. 2. ed. Lisboa: Edições Sílabo, 2000.

PONZONI, F. J.; GALVÃO, L. S.; LIESENBERG, V.; SANTOS, J.R. Impact of multiangular CHRIS/PROBA data on their empirical relationships with tropical forest biomass. **International Journal of Remote Sensing**, v. 31, n. 19, p. 5257-5273, 2010.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. Sensoriamento remoto da vegetação. 2. ed. Atualizada e ampliada – São Paulo: Oficina de textos, 2012. 164p.

REZENDE, A V; VALE, A T. DO; SANQUETTA, C. R.; FIGUEIREDO FILHO, A; FELFILI, J. M. Comparação de modelos matemáticos para estimativa do volume, biomassa e estoque de carbono da vegetação lenhosa de um cerrado sensu stricto em Brasília, DF. **Scientia Forestalis**, v. 71, p. 65–76, 2006.

RIBEIRO, J. F.; WALTER, B. M. T. Fitofisionomias do bioma Cerrado. In: SANO, S. M.; ALMEIDA, S. P. (eds.) **Cerrado:** ambiente e flora. Planaltina, DF: Embrapa-CPAC, 1998. p. 87-166.

RIBEIRO, S. C.; FEHRMANN, L.; SOARES, C. P. B.; JACOVINE, L. A. G.; KLEINN, C.; DE OLIVEIRA GASPAR, R. Above- and belowground biomass in a brazilian cerrado. **Forest Ecology and Management**, v. 262, n. 3, p. 491–499, 2011.

ROBERTS, D. A.; ROTH, K. L.; PERROY, R. L. Hyperspectral vegetation indices. In: THENKABAIL, P.S., LYON, J.G., HUETE, A. (Eds.), **Hyperspectral Remote Sensing of Vegetation**. CRC Press, Taylor and Francis Group, Boca Raton, FL. 2011. Chapter 14, p. 309–327.

ROCHA, A. J. A. Gestão e educação ambiental: plano de ação emergencial. In: FONSECA, F. O. (Org.). Águas Emendadas. 1 ed. Brasília: SEDUMA, 2008. cap. X-X.2, p. 353-358.

ROTH, K. L.; ROBERTS, D. A.; DENNISON, P. E.; ALONZO, M.; PETERSON, S. H.; BELAND, M. Differentiating plant species within and across diverse ecosystems with imaging spectroscopy. **Remote Sensing of Environment**, v. 167, p. 135–151, 2015b.

ROTH, K. L.; ROBERTS, D. A.; DENNISON, P. E.; PETERSON, S. H.; ALONZO, M. The impact of spatial resolution on the classification of plant species and functional types within imaging spectrometer data. **Remote Sensing of Environment**, v. 171, p. 45–57, 2015a.

ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W. Monitoring vegetation systems in the great plains with ERTS. In: ERTS-1 SYMPOSIUM, n. 3, [1973], Washington, DC. **Proceedings**...Washington: NASA. p. 309-317.

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, 2014.

SANO, E. E.; ROSA, R.; BRITO, J. L.; FERREIRA JR, L. G. Mapeamento semidetalhado do uso da terra do Bioma Cerrado. **Pesquisa Agropecuária Brasileira**, v. 43, p. 153-156, 2008.

SATO, M. N.; MIRANDA, H. S.; MAIA, J. M. F. O fogo e o estrato arbóreo do Cerrado: efeitos imediatos e a longo prazo. In: MIRANDA, H. S. (Ed.). **Efeitos do regime de fogo sobre a estrutura de comunidades de Cerrado**: Projeto Fogo. 1. ed. Brasília-DF: Ibama, 2010. p. 77–91.

SCHAEPMAN, M. E., USTIAN S.L., PLAZA A. J., PAINTER T. H., VERRELST J., LIANG S. Earth system science related imaging spectroscopy – An assessment. . **Remote Sensing of Environment**, v. 113 p. 123-137, 2009.

SCHILLING, A. C.; BATISTA, J. L. F. Curva de acumulação de espécies e suficiência amostral em florestas tropicais. **Revista Brasileira de Botânica**, v. 31, n. 1, p. 179–187, 2008.

SERRANO, L.; PENUELAS, 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, p. 355-364, 2002.

SHANG, X.; CHISHOLM, L. A. Classi fi cation of australian native forest species using hyperspectral remote sensing and machine-learning classi fi cation algorithms. **Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, p. 2481–2489, 2013.

SHAPIRO, S. S.; WILK, M. B. An analysis of variance test for normality (complete samples). **Biometrika**, v. 52, n. 3, p. 591–611, 1965.

SILVA JÚNIOR, M. C.; FELFILI, J. M. A vegetação da Estação Ecológica de Águas Emendadas. Brasília, DF: Instituto de Ecologia e Meio Ambiente do Distrito Federal, 1996. 43 p.

SNEDECOR, G. W.; COCHRAN, W. G. Statistical methods. 8. ed. Iowa: State University Press, 1989. 491p.

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.

SWATANTRAN, A.; DUBAYAH, R.; ROBERTS, D.; HOFTON, M.; BLAIR, J. B. Mapping biomass and stress in the sierra nevada using lidar and hyperspectral data fusion. **Remote Sensing of Environment**, v. 115, n. 11, p. 2917–2930, 2011.

TAGESSON, T.; FENSHOLT, R.; GUIRO, I.; RASMUSSEN, M. O.; HUBER, S.; MBOW, C.; GARCIA, M.; HORION, S.; SANDHOLT, I.; HOLM-RASMUSSEN, B.; GÖTTSCHE, F. M.; RIDLER, M.-E.; OLÉN, N.; LUNDEGARD OLSEN, J.; EHAMMER, A.; MADSEN, M.; OLESEN, F. S.; ARDÖ, J. Ecosystem properties of semiarid savanna grassland in west africa and its relationship with environmental variability. **Global Change Biology**, v. 21, n. 1, p. 250–64, 2015.

THENKABAIL, P. S.; ENCLONA, E. A.; ASHTON, M. S.; MEER, B. V. D. Accuracy assessments of hyperspectral waveband performance for vegetation analysis applications. **Remote Sensing Environment**, v. 91, p. 354–376, 2004.

TZANAKAKIS, V.; MAUROMOUSTAKOS, A.; ANGELAKIS, A. Prediction of biomass production and nutrient uptake in land application using partial least squares regression analysis. **Water**, v. 7, n. 1, p. 1–11, 2014.

UHLMANN, A.; GALVÃO, F.; SILVA, S. M. Análise da estrutura de duas comunidades fitofisionômicas de savana (cerrado) no sul do Brasil. Acta Botânica Brasílica, v. 12, p. 231-247, 1998.

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

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.

VYAS, D.; KRISHNAYYA, N. S. R. Estimating attributes of deciduous forest cover of a sanctuary in india utilizing hyperion data and pls analysis. **International Journal of Remote Sensing**, v. 35, n. 9, p. 3197–3218, 2014.

VYAS, D.; KRISHNAYYA, N. S. R.; MANJUNATH, K. R.; RAY, S. S.; PANIGRAHY, S. Evaluation of classifiers for processing hyperion (eo-1) data of tropical vegetation. **International Journal of Applied Earth Observation and Geoinformation**, v. 13, n. 2, p. 228–235, 2011.

WOLD, H. Estimation of principal components and related models by iterative least squares. In: KRISHNAIAAH P.R. (Ed.). **Multivariate Analysis.** New York, Academic Press. 1966. p. 391-420.

WOLD, S. Cross-validatory estimation of the number of in factor and principal components components models. **Technometrics**, v. 20, n. 4, p. 397–405, 1978.

WOLD, S. Personal memories of the early PLS development. Chemometrics and Intelligent Laboratory Systems, v. 58, p. 83–84, 2001.

	CLA	SSES	ARI	CAI	CRI1	EVI	LWVI2	MCARI	MSI	NDII	NDLI	NDVI	NDWI	PRI	PSRI	PSSR	RENDVI	REPI	RVSI	SIPI	VARI	VIG	VOG	WBI
	030V	Média	12,51	0,23	7,89	0,41	0,03	0,02	0,60	0,22	0,06	0,75	-0,07	-0,06	0,01	6,78	0,61	0,71	-0,01	1,07	0,29	0,18	1,41	1,02
	Chu	Desvio	1,58	0,99	1,68	0,02	0,03	0,00	0,05	0,04	0,01	0,02	0,02	0,02	0,01	0,65	0,03	0,00	0,01	0,02	0,06	0,03	0,03	0,06
C	03	Média	12,11	0,48	8,89	0,31	0,10	0,02	0,75	0,11	0,05	0,64	-0,10	-0,09	0,08	4,38	0,47	0,71	-0,01	1,16	0,07	0,05	1,30	1,02
	See	Desvio	0,90	1,17	1,86	0,02	0,04	0,00	0,07	0,05	0,01	0,03	0,02	0,03	0,02	0,49	0,05	0,00	0,01	0,03	0,05	0,04	0,03	0,07
	Muc	lança (%)	-3,19	109,70	12,78	-24,56	277,79	-15,26	23,68	-49,77	-22,39	-14,35	-56,90	-65,74	913,96	-35,41	-21,61	0,00	5,56	9,28	-74,98	-71,91	-8,03	0,03
	080	Média	12,66	0,52	8,12	0,38	0,00	0,02	0,65	0,19	0,06	0,72	-0,08	-0,06	0,02	6,01	0,56	0,71	-0,01	1,09	0,22	0,14	1,38	1,03
	Chuy	Desvio	0,90	1,06	1,46	0,02	0,04	39,47	0,06	0,04	0,01	0,03	0,02	0,02	0,02	0,76	0,05	0,00	0,01	0,03	0,07	0,04	0,03	0,07
C	c0	Média	11,82	0,43	7,69	0,28	0,05	0,02	0,90	0,02	0,05	0,59	-0,14	-0,09	0,12	3,64	0,39	0,71	-0,01	1,21	0,00	0,00	1,25	0,99
	Se	Desvio	0,81	1,43	1,77	0,02	0,04	0,00	0,09	0,05	0,01	0,04	0,02	0,02	0,03	0,42	0,05	0,00	0,01	0,05	0,05	0,03	0,03	0,07
	Muc	lança (%)	-6,66	-16,47	-5,25	-27,72	-3197,40	-14,07	39,71	-87,56	-24,27	-18,56	-67,34	-64,35	376,94	-39,55	-29,85	0,00	13,89	10,49	-101,54	-101,96	-9,94	-3,41
	080V	Média	11,31	0,50	7,31	0,36	-0,03	0,02	0,70	0,13	0,06	0,67	-0,09	-0,06	0,05	4,94	0,50	0,71	-0,01	1,13	0,15	0,10	1,33	1,02
	Chu	Desvio	1,19	0,98	1,32	0,02	0,04	0,00	0,06	0,05	0,01	0,03	0,02	0,02	0,02	0,66	0,04	0,00	0,00	0,03	0,05	0,03	0,04	0,06
CR	9	Média	10,58	1,00	6,13	0,24	0,01	0,01	1,07	-0,06	0,04	0,52	-0,17	-0,09	0,17	2,88	0,32	0,71	-0,01	1,30	-0,07	-0,05	1,19	0,98
	Se	Desvio	0,97	1,39	1,98	0,02	0,04	0,00	0,12	0,05	0,01	0,04	0,02	0,02	0,03	0,35	0,04	0,00	0,00	0,06	0,05	0,03	0,04	0,06
	Muc	lança (%)	-6,42	102,37	-16,18	-33,15	-156,10	-32,02	52,55	-146,28	-24,10	-23,60	-86,69	-41,17	232,52	-41,74	-37,13	0,00	24,65	14,57	-149,18	-153,24	-10,37	-3,48
	050V	Média	12,14	0,28	8,76	0,35	0,02	0,03	0,65	0,18	0,05	0,68	-0,05	-0,07	0,05	5,21	0,50	0,71	-0,02	1,12	0,15	0,10	1,35	1,03
	Chu	Desvio	0,99	0,98	1,57	0,02	0,05	0,01	0,06	0,05	0,01	0,03	0,04	0,02	0,02	0,59	0,04	0,00	0,00	0,02	0,04	0,03	0,04	0,07
CaC	50	Média	11,13	0,34	7,65	0,23	0,02	0,02	1,03	-0,03	0,04	0,50	-0,14	-0,09	0,21	2,78	0,29	0,71	-0,01	1,35	-0,11	-0,08	1,20	0,98
	Se	Desvio	1,24	1,57	1,78	0,02	0,04	0,00	0,13	0,06	0,01	0,03	0,03	0,02	0,03	0,26	0,04	0,00	0,00	0,05	0,03	0,03	0,04	0,07
	Muc	lança (%)	-8,36	20,23	-12,67	-34,62	-27,61	-39,37	57,66	-118,06	-24,66	-26,39	-196,29	-37,52	303,11	-46,74	-42,82	0,03	37,13	20,51	-170,71	-176,51	-10,98	-4,65

APÊNDICE A - Média, desvio padrão e porcentagem de mudança para cada índice de vegetação calculado para o período chuvoso e seco.

Continua...

	CLA	SSES	ARI	CAI	CRI1	EVI	LWVI2	MCARI	MSI	NDII	NDLI	NDVI	NDWI	PRI	PSRI	PSSR	RENDVI	REPI	RVSI	SIPI	VARI	VIG	VOG	WBI
	080	Média	10,02	0,61	6,33	0,34	-0,02	0,03	0,74	0,09	0,06	0,62	-0,10	-0,05	0,08	4,13	0,42	0,71	-0,02	1,15	0,08	0,05	1,28	1,00
	Chuy	Desvio	1,15	0,86	1,25	0,03	0,03	0,01	0,06	0,05	0,01	0,04	0,02	0,02	0,02	0,57	0,04	0,00	0,00	0,04	0,05	0,04	0,04	0,06
CaS	00	Média	9,28	1,09	4,77	0,19	-0,04	0,01	1,32	-0,17	0,04	0,43	-0,20	-0,07	0,24	2,25	0,20	0,71	-0,01	1,45	-0,14	-0,10	1,15	0,95
	Se	Desvio	1,22	1,30	1,38	0,02	0,04	0,00	0,15	0,06	0,01	0,05	0,03	0,02	0,04	0,34	0,05	0,01	0,00	0,10	0,05	0,03	0,03	0,06
	Mu	dança (%)	-7,37	77,20	-24,71	-42,97	64,49	-54,56	78,84	-279,18	-25,80	-31,41	-98,53	-30,93	217,68	-45,57	-51,45	0,12	46,42	25,38	-273,18	-282,49	-9,97	-4,34
	V050	Média	9,78	-0,13	6,50	0,28	-0,03	0,02	0,80	0,08	0,05	0,56	-0,07	-0,07	0,11	3,51	0,38	0,71	-0,02	1,22	0,03	0,02	1,27	1,02
	Chu	Desvio	1,49	1,09	1,93	0,04	0,05	0,01	0,11	0,08	0,01	0,06	0,04	0,02	0,03	0,66	0,05	0,00	0,00	0,05	0,05	0,04	0,04	0,08
CaL	00	Média	6,88	0,61	4,28	0,15	-0,04	0,01	1,33	-0,16	0,04	0,32	-0,18	-0,08	0,33	1,77	0,13	0,71	-0,01	1,68	0,00	-0,13	1,11	0,96
	Se	Desvio	1,69	2,14	1,55	0,02	0,04	0,00	0,13	0,06	0,01	0,04	0,03	0,02	0,04	0,17	0,03	0,01	0,00	0,11	0,04	0,03	0,02	0,08
	Mu	dança (%)	-29,59	-584,17	-34,24	-46,29	39,42	-60,87	65,61	-301,15	-26,86	-43,02	-136,27	-17,97	192,59	-49,52	-66,63	0,43	47,89	38,05	-100,00	-789,37	-12,24	-5,32
	V0S0	Média	14,38	0,11	10,82	0,47	0,11	0,02	0,48	0,31	0,06	0,82	-0,02	-0,08	-0,02	10,34	0,72	0,71	0,00	1,04	0,45	0,28	1,49	1,07
	Chu	Desvio	1,17	0,91	1,92	0,02	0,05	0,00	0,03	0,03	0,01	0,02	0,02	0,02	0,01	1,05	0,02	0,00	0,00	0,01	0,06	0,03	0,05	0,07
MG	c0	Média	13,75	-0,14	16,20	0,45	0,27	0,02	0,42	0,34	0,04	0,80	0,02	-0,14	0,02	9,54	0,69	0,71	0,00	1,08	0,34	0,25	1,45	1,11
	Se	Desvio	1,16	1,15	3,75	0,04	0,07	0,01	0,06	0,05	0,01	0,03	0,03	0,03	0,01	1,84	0,04	0,00	0,00	0,02	0,08	0,06	0,06	0,07
	Mu	dança (%)	-4,38	-219,76	49,74	-5,17	153,10	15,15	-11,59	8,81	-21,42	-2,80	210,16	-69,76	180,31	-7,78	-4,08	0,00	-365,71	3,56	-24,52	-12,40	-2,76	3,06

Conclusão

# APÊNDICE B - MATRIZ DE CONFUSÃO PARA CADA CONJUNTO DE MÉTRICAS HIPERESPECTRAIS EM CADA PERÍODO (CHUVOS E SECO).

Classes	CD	С	CR	CaC	CaS	CaL	MG	Total (pixels)	Acurácia usuário (%)
CD	37	7	0	1	0	0	0	45	82,2
С	12	21	11	0	0	0	0	44	47,7
CR	1	12	32	0	0	0	1	46	69,6
CaC	0	0	3	40	3	0	0	46	87,0
CaS	0	2	3	3	36	1	0	45	80,0
CaL	0	0	0	3	8	32	0	43	74,4
MG	1	0	0	0	0	0	41	42	97,6
Total (pixels)	51	42	49	47	47	33	42	311	
Acurácia do produtor (%)	72,5	50,0	65,3	85,1	76,6	97,0	97,6		
Acurácia global (%)	76,8								
Índice Kappa	0,73								

Tabela B.1. Resultados da Classificação por MDA para o conjunto reflectância de bandas no período chuvoso.

Tabela B.2. Resultados da Classificação por MDA para o conjunto reflectância de bandas no período seco.

Classes	CD	С	CR	CaC	CaS	CaL	MG	Total (pixels)	Acurácia usuário (%)
CD	36	5	0	1	0	0	1	43	83,7
С	13	22	8	1	0	0	0	44	50,0
CR	2	5	29	8	1	0	0	45	64,4
CaC	0	0	6	30	5	0	0	41	73,2
CaS	0	1	3	3	36	1	0	44	81,8
CaL	0	0	0	0	6	39	0	45	86,7
MG	1	0	0	0	0	0	40	41	97,6
Total (pixels)	52	33	46	43	48	40	41	303	
Acurácia do produtor (%)	69,2	66,7	63,0	69,8	75,0	97,5	97,6		
Acurácia global (%)	76,6								
Índice Kappa	0,73								

Classes	CD	С	CR	CaC	CaS	CaL	MG	Total (pixels)	Acurácia do usuário (%)
CD	34	10	0	1	0	0	0	45	75,6
С	12	15	8	8	1	0	0	44	34,1
CR	1	8	32	4	1	0	0	46	69,6
CaC	0	1	6	36	3	0	0	46	78,3
CaS	0	1	3	2	37	2	0	45	82,2
CaL	0	0	0	3	8	31	0	42	73,8
MG	0	0	0	0	0	0	42	42	100,0
Total (pixels)	47	35	49	54	50	33	42	310	
Acurácia do produtor (%)	72,3	42,9	65,3	66,7	74,0	93,9	100,0		
Acurácia global (%)	73,2								
Índice Kappa	0,69								

Tabela B.3. Resultados da Classificação por MDA para o conjunto índices de vegetação no período chuvoso.

Tabela B.4. Resultados da Classificação por MDA para o conjunto índices de vegetação no período seco.

Classes	CD	С	CR	CaC	CaS	CaL	MG	Total (pixels)	Acurácia do usuário (%)
CD	38	5	0	0	0	0	0	43	88,4
С	10	27	7	0	0	0	0	44	61,4
CR	1	10	28	5	1	0	0	45	62,2
CaC	0	0	3	33	5	0	0	41	80,5
CaS	0	0	4	2	35	3	0	44	79,5
CaL	0	0	0	1	3	41	0	45	91,1
MG	2	0	0	0	0	0	39	41	95,1
Total (pixels)	51	42	42	41	44	44	39	303	
Acurácia do produtor (%)	74,5	64,3	66,7	80,5	79,5	93,2	100,0		
Acurácia global (%)	79,5								
Índice Kappa	0,76								
Classes	CD	С	CR	CaC	CaS	CaL	MG	Total (pixels)	Acurácia do usuário (%)
--------------------------	------	------	------	------	------	------	------	-------------------	----------------------------
CD	27	13	2	2	0	0	6	50	54,0
С	14	21	3	10	2	0	0	50	42,0
CR	3	11	25	9	2	0	0	50	50,0
CaC	0	4	9	27	10	0	0	50	54,0
CaS	0	0	2	9	32	7	0	50	64,0
CaL	0	0	0	2	14	34	0	50	68,0
MG	6	0	0	0	0	0	44	50	88,0
Total (pixels)	50	49	41	59	60	41	50	350	
Acurácia do produtor (%)	54,0	42,9	61,0	45,8	53,3	82,9	88,0		
Acurácia global (%)	60,0								
Índice Kappa	0,53								

Tabela B.5. Resultados da Classificação por MDA para o conjunto parâmetros de bandas de absorção no período chuvoso.

Tabela B.6. Resultados da Classificação por MDA para o conjunto parâmetros de bandas de absorção no período seco.

Classes	CD	С	CR	CaC	CaS	CaL	MG	Total (pixels)	Acurácia do usuário (%)
CD	32	16	0	0	0	0	2	50	64,0
С	11	33	1	5	0	0	0	50	66,0
CR	0	13	22	11	4	0	0	50	44,0
CaC	0	0	10	32	7	0	1	50	64,0
CaS	0	0	4	6	33	7	0	50	66,0
CaL	0	0	0	1	11	38	0	50	76,0
MG	0	0	0	0	0	0	50	50	100,0
Total (pixels)	43	62	37	55	55	45	53	350	
Acurácia do produtor (%)	74,4	53,2	59,5	58,2	60,0	84,4	94,3		
Acurácia global (%)	68,6								
Índice Kappa	0,63								

Classes	CD	С	CR	CaC	CaS	CaL	MG	Total (pixels)	Acurácia do usuário (%)
CD	36	8	0	1	0	0	0	45	80,0
С	10	25	9	0	0	0	0	44	56,8
CR	3	8	35	0	0	0	0	46	76,1
CaC	0	0	3	42	1	0	0	46	91,3
CaS	0	2	3	1	38	1	0	45	84,4
CaL	0	0	0	2	6	35	0	43	81,4
MG	0	0	0	0	0	0	42	42	100,0
Total (pixels)	49	43	50	46	45	36	42	311	
Acurácia do produtor (%)	73,5	58,1	70,0	91,3	84,4	97,2	100,0		
Acurácia global (%)	81,4								
Índice Kappa	0,78								

Tabela B.7. Resultados da Classificação por MDA para todos os atributos gerados no período chuvoso.

Tabela B.8. Resultados da Classificação por MDA para o todos os atributos gerados no período seco.

Classes	CD	С	CR	CaC	CaS	CaL	MG	Total (pixels)	Acurácia do usuário (%)
CD	36	7	0	0	0	0	0	43	83,7
С	10	29	5	0	0	0	0	44	65,9
CR	0	5	36	4	0	0	0	45	80,0
CaC	0	0	5	34	2	0	0	41	82,9
CaS	0	0	2	2	39	1	0	44	88,6
CaL	0	0	0	0	4	41	0	45	91,1
MG	1	0	0	0	0	0	40	41	97,6
Total (pixels)	47	41	48	40	45	42	40	303	
Acurácia do produtor (%)	76,6	70,7	75,0	85,0	86,7	97,6	100,0		
Acurácia global (%)	84,2								
Índice Kappa	0,82								