



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



sid.inpe.br/mtc-m21d/2022/02.22.12.51-TDI

**USO DE MÉTRICAS FENOLÓGICAS CALCULADAS DE
DIFERENTES ÍNDICES DE VEGETAÇÃO DA
CONSTELAÇÃO DE SATÉLITES PLANETSCOPE PARA
CLASSIFICAÇÃO DE FITOFISIONOMIAS DO
CERRADO**

Isadora Haddad Ruiz

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Lênio Soares Galvão, e
Fábio Marcelo Breunig, aprovada
em 11 de fevereiro de 2022.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/46DD25B>>

INPE
São José dos Campos
2022

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Coordenação de Ensino, Pesquisa e Extensão (COEPE)
Divisão de Biblioteca (DIBIB)
CEP 12.227-010
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/7348
E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

Membros:

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



sid.inpe.br/mtc-m21d/2022/02.22.12.51-TDI

**USO DE MÉTRICAS FENOLÓGICAS CALCULADAS DE
DIFERENTES ÍNDICES DE VEGETAÇÃO DA
CONSTELAÇÃO DE SATÉLITES PLANETSCOPE PARA
CLASSIFICAÇÃO DE FITOFISIONOMIAS DO
CERRADO**

Isadora Haddad Ruiz

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Lênio Soares Galvão, e
Fábio Marcelo Breunig, aprovada
em 11 de fevereiro de 2022.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/46DD25B>>

INPE
São José dos Campos
2022

Dados Internacionais de Catalogação na Publicação (CIP)

Ruiz, Isadora Haddad.

R859u Uso de métricas fenológicas calculadas de diferentes índices de vegetação da constelação de satélites PlanetScope para classificação de fitofisionomias do Cerrado / Isadora Haddad Ruiz. – São José dos Campos : INPE, 2022.

xviii + 73 p. ; (sid.inpe.br/mtc-m21d/2022/02.22.12.51-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2022.

Orientadores : Drs. Lênio Soares Galvão, e Fábio Marcelo Breunig.

1. Fenologia da vegetação. 2. PlanetScope. 3. Cerrado. 4. Constelação de satélites. 5. Classificação. I.Título.

CDU 528.8:581.54



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

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

MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

DEFESA FINAL DE DISSERTAÇÃO DA ISADORA HADDAD RUIZ
BANCA Nº022/2022, REG 450845/2020

No dia 11 de fevereiro de 2022, às 09h00min, por teleconferência, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestra em Sensoriamento Remoto. O trabalho precisa da incorporação das correções sugeridas pela Banca e revisão final pelo(s) orientador (es).

Título: “Uso de métricas fenológicas calculadas de diferentes índices de vegetação da constelação de satélites PlanetScope para classificação de fitofisionomias do cerrado”

Membros da Banca:

Dr. Thales Sehn Körting - Presidente (INPE/DIOTG)

Dr. Lênio Soares Galvão - Orientador(a) (INPE/DIOTG)

Dr. Fábio Marcelo Breunig - Orientador (UFSM)

Dr. Vandoir Bourscheidt - Membro da banca (UFSCar)



Documento assinado eletronicamente por **Thales Sehn Korting, Pesquisador**, em 11/02/2022, às 15:54 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **VANDOIR BOURSCHIEDT (E), Usuário Externo**, em 11/02/2022, às 17:40 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Fabio Marcelo Breunig (E), Usuário Externo**, em 14/02/2022, às 08:23 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Lênio Soares Galvão, Pesquisador**, em 14/02/2022, às 14:07 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <http://sei.mctic.gov.br/verifica.html>, informando o código verificador **9393588** e o código CRC **DF5EA3C2**.

Referência: Processo nº 01340.000908/2022-49

SEI nº 9393588

AGRADECIMENTOS

Agradeço ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão da bolsa de mestrado (131042/2020-3).

Ao Programa de Pós-Graduação em Sensoriamento Remoto do Instituto Nacional de Pesquisas Espaciais (INPE), por disponibilizar as instalações e recursos no desenvolvimento deste estudo.

A PlanetLabs pelo fornecimento das imagens (via programa de pesquisa e educação da empresa).

Ao Instituto Brasília Ambiental (IBRAM) pela autorização de pesquisa 06/2015 (projeto 391.000.740/2015).

Ao meu orientador Dr. Lênio Soares Galvão, pelo suporte, amparo em tempos tão difíceis, atenção para a realização do trabalho e transferência de conhecimento ao longo dessa trajetória. Ao orientador Dr. Fábio Marcelo Breunig, por toda colaboração na condução do trabalho.

Ao Dr. Vandoir Bourcsheidt, pela orientação ainda na graduação e contribuição com a minha trajetória acadêmica. Ao Dr. Ricardo Dalagnol, por todo suporte científico e parceria durante o mestrado.

Aos professores da PG-SER que enfrentaram o ensino remoto e zelaram pela qualidade e rigor científico das atividades. As meninas que cuidam dos prédios SERE e ASA que, indiretamente, nos dedicam atenção.

A Deborah, Rejane, Lorena, Maria Lúcia, Phellipe, Mario, Gabs e Sá, fundamentais para a minha permanência no mestrado e que mesmo distantes estiveram tão presentes. Em especial, a Karol, Maíra e Pepê por me receberem com tanto carinho e serem grandes parceiras.

A minha mãe (Jana), minhas irmãs (Isabela e Eduarda) e meu companheiro (Felipe), por todo suporte e incentivo incondicional.

RESUMO

O mapeamento da vegetação nativa do Cerrado no Brasil é desafiador, não havendo um consenso sobre a melhor estratégia de sensoriamento remoto para lidar com a variabilidade espacial de algumas fitofisionomias e a similaridade espectral de outras. Neste estudo, avaliou-se o desempenho de 12 métricas fenológicas (*Land Surface Phenology* - LSP) calculadas a partir de três diferentes índices de vegetação (IV) da constelação de satélites PlanetScope (PS). As métricas foram usadas como variáveis de entrada para o algoritmo de aprendizado de máquina Random Forest (RF), visando classificar oito fitofisionomias do Cerrado. A área de estudo foi a Estação Ecológica de Águas Emendadas (ESAE), localizada na região central do Brasil. Testou-se a classificação LSP na estação de crescimento 2017-2018 contra a classificação IV na estação seca de 2017, usando um mapa disponível de vegetação como referência para avaliação da precisão dos resultados. Além disso, analisou-se o desempenho do uso combinado (todos os IVs ou métricas LSP em conjunto) e individual (cada IV ou métricas LSP usadas separadamente) das variáveis na classificação RF das fitofisionomias. Os resultados mostraram que a acurácia total (OA) da classificação RF usando 12 imagens PS adquiridas na estação seca de 2017, variou de 0,56 para o *Green-Red Normalized Difference* (GRND) a 0,57 e 0,61 para o *Enhanced Vegetation Index* (EVI) e *Normalized Difference Vegetation Index* (NDVI), respectivamente. As métricas LSP, determinadas durante a estação de crescimento de 2017-2018, produziram ganhos de 19,3% (EVI), 13,1% (NDVI) e 5,4% (GRND), quando comparadas com o uso isolado de IVs da estação seca. Mantendo o EVI da estação seca como referência para comparação, o uso combinado dos IVs (OA = 0,70) ou métricas LSP (OA = 0,73) produziu ganhos na OA de 22,8% e 28,1%, respectivamente. As variáveis mais significativas para o modelo RF empregando conjuntamente as métricas LSP foram obtidas principalmente do NDVI e EVI, sendo elas: o valor mínimo (TRG) e máximo (PEAK) de IV; o valor médio na primavera (MSP); o valor médio na estação de crescimento (MGS); e a taxa de verdejamento na primavera (RSP). Os resultados mostraram a importância de se utilizar dados de alta resolução espacial e temporal da constelação de satélites PlanetScope para classificar fitofisionomias de Cerrado, usando informações de fenologia da vegetação. Além disso, quando séries temporais densas não estiverem disponíveis para calcular adequadamente as métricas LSP, uma alternativa é o uso combinado de IVs com sensibilidades diferentes aos parâmetros biofísicos da vegetação. Isto é válido especialmente para dados de satélite adquiridos durante a estação seca local, quando a frequência de cobertura de nuvens é reduzida.

Palavras-chave: Fenologia da vegetação. PlanetScope. Cerrado. Constelação de satélites. Classificação.

USE OF PHENOLOGICAL METRICS CALCULATED FROM DIFFERENT VEGETATION INDICES OF THE PLANETSCOPE SATELLITE CONSTELLATION FOR CLASSIFYING SAVANNA PHYSIOGNOMIES

ABSTRACT

Mapping of savannas in Brazil is challenging since there is no consensus on the best remote sensing strategy to deal with the spatial variability of some physiognomies and the spectral similarity among others. In this study, we evaluated the performance of 12 land surface phenology (LSP) metrics calculated from three PlanetScope (PS) vegetation indices (VIs) for Random Forest (RF) classification of eight savanna physiognomies. At the protected Ecological Station of Águas Emendadas (ESAE) located in central Brazil, we tested the LSP classification in the 2017-2018 growing season against the dry-season VI classification in 2017 using an available vegetation map for accuracy assessment. Furthermore, we analyzed the performance of individual (each set of VIs or LSP metrics used separately) and combined (all VIs or LSP metrics used together) metrics for RF classification of the savanna physiognomies. The results showed that the overall accuracy (OA) of RF classification using 12 PS images acquired in the 2017 dry season ranged from 0.56 for the Green-Red Normalized Difference (GRND) to 0.57 and 0.61 for the Enhanced Vegetation Index (EVI) and Normalized Difference Vegetation Index (NDVI), respectively. The LSP metrics retrieved during the 2017-2018 growing season produced gains in OA of 19.3% (EVI), 13.1% (NDVI) and 5.4% (GRND) when compared to the individual use of VIs in the dry season. Keeping the dry-season EVI as a reference of comparison, the combined use of VIs (OA = 0.70) or LSP metrics (OA = 0.73) also generated gains in OA of 22.8% and 28.1%, respectively. The most important ranked LSP metrics from the combination of this type of variable were mainly calculated from the NDVI and EVI: the minimum (TRG) and maximum (PEAK) VI values; the mean Spring (MSP); the mean growing season (MGS); and the rate of spring green up (RSP). The results show the importance of the combined use of high spatial and temporal resolution data of the Planet's satellite constellation for the classification of Brazilian savannas using the vegetation phenology information. Besides that, when dense time series are not available for retrieving the LSP metrics, an alternative is the combined use of different VIs for satellite data acquired during the dry season when the frequency of cloud cover is reduced.

Keywords: Cerrado. Ensemble metrics. Land surface phenology. Random Forest. Satellite constellation. Savannas.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 - Biomas do Brasil e estados de abrangência.	7
Figura 2.2 - Gradiente de vegetação de formações naturais do Cerrado.	8
Figura 2.3 - Métricas fenológicas derivadas do ciclo de crescimento da vegetação a partir do algoritmo Greenbrown.	19
Figura 3.1 - Localização da Estação Ecológica de Águas Emendadas (ESAE) no bioma Cerrado. Uma composição falsa-cor da constelação de satélites PlanetScope é mostrada com as bandas 4(NIR), 2(G) e 1(B) exibidas em RGB, respectivamente.	23
Figura 3.2 - Precipitação acumulada mensal em 2017 e 2018 comparada ao padrão médio da precipitação no período de 2009 a 2020. Os dados foram medidos pela estação meteorológica automática A045 do Instituto Nacional de Meteorologia (INMET). A estação seca (maio a setembro) é indicada na parte superior.	23
Figura 3.3 - Fitofisionomias de Cerrados presentes na ESAE representadas por imagens PlanetScope Falsa Cor (4-3-2) e índices de vegetação NDVI, EVI e GRND. As imagens foram adquiridas em 01/09/2017.	27
Figura 3.4 - Registros fotográficos das fitofisionomias da ESAE.	28
Figura 4.1 - Diagrama metodológico com as etapas do processo de classificação RF de savanas para avaliar o uso de métricas fenológicas da vegetação versus índices de vegetação na estação seca.	29
Figura 4.2 - Frequência de imagens livres de nuvens (linhas pretas na vertical na representação inferior) adquiridas pela PlanetScope (PS) sobre a área de estudo durante a estação de crescimento 2017-2018. A precipitação diária registrada no período de análise pela estação meteorológica automática A045 é mostrada na representação superior. ...	31
Figura 5.1 - Variações sazonais no (a) NDVI, (b) EVI e (c) GRND durante a estação de crescimento 2017-2018 para cinco das oito fitofisionomias de Cerrado com adensamento da cobertura vegetal de CL para MG.	38
Figura 5.2 - Mudança média no NDVI, EVI e GRND com a ocorrência dos primeiros eventos de chuva no final de setembro de 2017. Os resultados referem-se a áreas representativas das fitofisionomias de Cerrado com incremento da cobertura vegetal. .	39

Figura 5.3 - Variação espacial de algumas métricas fenológicas, derivadas dos diferentes índices de vegetação (NDVI, EVI e GRND) pelo algoritmo greenbrown, quando comparado ao mapa de referência da vegetação da ESAE.....	40
Figura 5.4 - Variações nos valores máximos (PEAK) e mínimos (TRG) de (a) NDVI, (b) EVI e (c) GRND para as oito fitofisionomias em estudo. As letras indicam diferenças estatísticas entre as métricas fenológicas ao nível de 5% de significância (Tukey-Kramer teste).	42
Figura 5.5 - Diferenças na Precision, Recall e F1-score entre as abordagens de classificação Random Forest da estação seca de 2017, com índices de vegetação, e do ciclo sazonal de 2017-2018 com métricas fenológicas (LSP).....	45
Figura 5.6 - Classificação Random Forest com o uso individual dos IVs da estação seca e das métricas fenológicas LSP para uma porção da ESAE onde ocorre concentração de seis fitofisionomias distintas.....	46
Figura 5.7 - Métricas LSP mais importantes para o modelo de classificação da abordagem conjunta usando 36 variáveis preditoras, expressas por valores de Mean Decrease in Accuracy calculada de 30 permutações ao nível de significância de 5%.....	49
Figura 5.8 - (a) Mapa da vegetação da Estação Ecológica de Águas Emendadas (ESAE). Classificação Random Forest da abordagem conjunta: (b) índices de vegetação na estação seca de 2017 e (c) métricas da fenologia da superfície (LSP) na estação de crescimento 2017-2018. As imagens de entropia correspondentes são apresentadas em (d) e (e), respectivamente.	51
Figura A.1 - Classificação RF de IVs da estação seca (2017) e métricas LSP (estação de crescimento 2017-2018) a partir de IVs isolados (abordagem não conjunta).	69
Figura C.1 - Boxplot entropia de Shannon por fitofisionomia savânica.	73

LISTA DE TABELAS

Pág.

Tabela 2.1 - Faixa espectral dos sensores PlanetScope da primeira (PS2 - 2016), segunda (PS2.SD - 2018) e terceira (PSB.SD - 2020) geração.	13
Tabela 3.1 - Características das fitofisionomias e tipo de solo em que ocorrem, na Estação Ecológica de Águas Emendadas (ESAE).	26
Tabela 5.1 - Matriz de erro da classificação Random Forest de oito fitofisionomias de Cerrado usando 12 imagens PlanetScope da estação seca de 2017 e métricas LSP dos índices de vegetação (NDVI, EVI e GRND).	44
Tabela 5.2 - Matriz de erro da classificação Random Forest de oito fitofisionomias de Cerrado, usando a abordagem conjunta de 36 índices de vegetação da estação seca (12 datas de NDVI, EVI e GRND) e 36 métricas da fenologia da superfície (LSP) (12 variáveis preditoras por IV: NDVI, EVI e GRND).	48
Tabela B.1 - NDVI da estação seca de 2017.	70
Tabela B.2 - EVI da estação seca de 2017.	70
Tabela B.3 - GRND da estação seca de 2017.	71
Tabela B.4 - NDVI métricas LSP (ciclo de crescimento 2017-2018).	71
Tabela B.5 - EVI métricas LSP (ciclo de crescimento 2017-2018).	72
Tabela B.6 - GRND métricas LSP (ciclo de crescimento 2017-2018).	72

LISTA DE SIGLAS E ABREVIATURAS

APA	Área de Proteção Ambiental
CC	Campo Cerrado
CD	Cerrado Denso
CL	Campo Limpo
CR	Campo Ralo
CS	Campo Sujo
CT	Cerrado Típico
DOY	Dia do ano
EOS	Final da estação de crescimento
ESAE	Estação Ecológica de Águas Emendadas
EVI	<i>Enhanced Vegetation Index</i>
F	F1-score
GRND	<i>Green-Red Normalized Difference</i>
IV	Índice de Vegetação
LACC	<i>Locally Adjusted Cubic-spline</i>
LOS	Comprimento da estação
LSP	<i>Land Surface Phenology</i>
MAU	Valor médio no outono
MDA	<i>Mean Decrease in Accuracy</i>
MG	Mata de Galeria
MGS	Valor médio na estação de crescimento
MODIS	<i>Moderate Resolution Imaging Spectrometer</i>
MSP	Valor médio na primavera
NDVI	<i>Normalized Difference Vegetation Index</i>
NIR	<i>Near infrared</i>
OA	<i>Overall Accuracy</i>
P	<i>Precision</i>
PEAK	Valor máximo
POP	Posição do valor máximo
POT	Posição do valor mínimo
PS	PlanetScope
R	<i>Recall</i>

RAU	Taxa de senescência no outono
RF	Random Forest
RSP	Taxa de green up na primavera
SOS	Início da estação de crescimento
SWIR	<i>Shortwave infrared</i>
TC	<i>Tasseled-cap</i>
TRG	Valor mínimo
UDM	<i>Unusable Data Mask</i>
VE	Veredas

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Hipótese de trabalho.....	4
1.2 Objetivos	5
1.2.1 Geral.....	5
1.2.2 Específicos	5
2 FUNDAMENTAÇÃO TEÓRICA	6
2.1 O bioma “Cerrado”.....	6
2.2 Constelação de satélites PlanetScope (PS).....	11
2.3 Fenologia da vegetação	13
2.3.1 PlanetScope e fenologia da vegetação	14
2.4 Índice de Vegetação (IVs).....	15
2.5 Algoritmo Greenbrown	17
2.6 Random Forest (RF).....	19
3 ÁREA DE ESTUDO	22
4 METODOLOGIA	29
4.1 Seleção da área de estudo.....	29
4.2 Aquisição dos dados PlanetScope e pré-processamento da série temporal	30
4.3 Determinação das métricas fenológicas	31
4.4 Análise dos dados.....	32
4.4.1 Resposta sazonal das fitofisionomias do Cerrado.....	32
4.4.2 Classificação Random Forest para a estação seca (IVs) versus fenologia da vegetação (métricas LSP).....	33
4.4.3 Classificação Random Forest para uso combinado versus conjunto isolado das variáveis.....	34
4.5 Validação.....	34
5 RESULTADOS.....	37
5.1 Resposta sazonal dos índices de vegetação nas savanas	37
5.2 Variações espaciais nas métricas fenológicas	39
5.3 Classificação IVs da estação seca versus LSP	42

5.4 Classificação para a abordagem conjunta de IVs e métricas LSP.....	47
6 DISCUSSÃO.....	53
7 CONCLUSÃO.....	58
REFERÊNCIAS BIBLIOGRÁFICAS	60
APÊNDICE A – CLASSIFICAÇÃO RANDOM FOREST A PARTIR DO USO ISOLADO DAS VARIÁVEIS	69
APÊNDICE B – MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO RF DA ESTAÇÃO SECA E MÉTRICAS LSP POR IV ISOLADO.....	70
APÊNDICE C -VALORES DE ENTROPIA POR FITOFISIONOMIAS PARA AS CLASSIFICAÇÕES DE USO COMBINADO DE VARIÁVEIS DA ESTAÇÃO SECA (36 IVs) E MÉTRICAS LSP (36 MÉTRICAS LSP)	73

1 INTRODUÇÃO

As savanas do Brasil, localmente conhecidas como “Cerrado”, representam o segundo maior bioma do país, sendo menor apenas que o ecossistema Amazônico. Com área maior que 200 milhões de hectares (FERREIRA et al., 2011; TRANCOSO et al., 2015), as savanas são consideradas *hotspot* mundial de biodiversidade (MYERS et al., 2000; JACON et al., 2017). A vegetação nativa é composta por alta diversidade de espécies bem adaptadas ao fogo e a forte sazonalidade da precipitação entre a estação seca e a chuvosa (EITEN, 1982; SARMIENTO, 1983; RATTER et al., 2006). Um gradiente de vegetação, variando de formações campestres a florestais, é geralmente observado nas áreas de savanas. Isto depende de diversos fatores como a umidade do solo, os nutrientes e a distribuição das chuvas (RIBEIRO; WALTER, 1998; OLIVEIRA-FILHO; RATTER, 2002).

Peculiaridades acerca das condições ambientais e das adaptações das espécies encontradas no bioma fazem do Cerrado um ecossistema único com alto grau de espécies endêmicas. Algumas espécies desenvolveram-se na presença de incêndios periódicos que ocorrem principalmente no final da estação seca, em decorrência de descargas elétricas naturais (raios), atividades antrópicas (principal fator) e acúmulo de biomassa seca (combustível para o fogo). Entre as adaptações notáveis, destacam-se árvores apresentando cascas espessas e resistentes ao fogo (DANTAS; BATALHA; PAUSAS, 2013). Para algumas espécies, o fogo atua na quebra de dormência e reprodução (FIDELIS et al., 2019), provendo, assim, a manutenção de processos ecológicos (PIVELLO, 2011b; DANTAS; BATALHA; PAUSAS, 2013; DURIGAN; RATTER, 2016). Em contrapartida, o manejo inadequado e o uso de maneira desproporcional do fogo, ou seja, frequência e recorrência elevada em ambientes de Cerrado, pode resultar em substituição de formações savânicas nativas por outros tipos de vegetação (DURIGAN; RATTER, 2016), afetando o funcionamento regular do ecossistema e produzindo mortalidade de árvores (FLORES et al., 2020).

A boa estrutura física dos solos e o relevo plano, junto com a disponibilidade de água, impulsionaram o avanço de atividades agropecuárias no Cerrado (PIVELLO, 2011a; SANO et al., 2019a). Como consequência, o bioma corresponde à principal fronteira agrícola do país (SANO et al., 2019; SOUZA et al., 2020; ALENCAR et al., 2020), com

taxas de desmatamento que superam em área o desmatamento na Amazônia (SANO et al., 2019b). Atualmente o bioma conta com uma paisagem altamente fragmentada, onde apenas 55% de área do Cerrado ainda está coberta por vegetação nativa (SANO et al., 2010; BISPO et al., 2020).

A intensificação dessas atividades é uma ameaça eminente à estabilidade ecológica e a manutenção dos serviços ecossistêmicos prestados pelas savanas brasileiras. Para reduzir os impactos do desmatamento e desequilíbrio ecológico, o mapeamento de áreas preservadas é uma importante iniciativa. Ela facilita, por exemplo: (a) o estudo do balanço de carbono, ciclagem de nutrientes e recursos hídricos; (b) a seleção de novas áreas para conservação de biodiversidade; (c) o monitoramento de áreas preservadas e a prevenção de distúrbios (fogo e desmatamento); e (d) o entendimento da dinâmica da vegetação e da resposta do ecossistema para cenários de mudanças ambientais globais e do uso local do solo (COE et al., 2009; RATANA et al., 2005; SCHWIEDER et al., 2016; DE SOUZA et al., 2020; 2021).

Nessa esfera, esforços direcionados ao mapeamento das diferentes fitofisionomias de Cerrado são reportados na literatura. No entanto, esta tarefa ainda é vista como um desafio. A variabilidade espacial de algumas fisionomias e a similaridade espectral de outras (SANO et al., 2005; LIESENBERG et al., 2007; JACON et al., 2017; TONIOL et al., 2017) são as principais dificuldades encontradas para discriminar as tipologias de vegetação savânica. Da perspectiva do sensoriamento remoto óptico, o período mais favorável para mapear fitofisionomias do Cerrado é a estação seca (junho a setembro), quando a frequência de nuvens é reduzida. Porém, em ambientes savânicos, as fitofisionomias têm sensibilidades distintas para a sazonalidade da precipitação (JACON et al., 2021). Por exemplo, formações campestres são mais sensíveis ao déficit hídrico na estação seca do que formações florestais, em razão das plantas herbáceas e gramíneas terem raízes rasas e com acesso mais difícil à água existente em camadas mais profundas do solo (JACON et al., 2017). Tais diferenças sazonais na resposta da vegetação podem servir como fonte de informações para classificar a vegetação a partir do sensoriamento remoto.

O uso de métricas fenológicas extraídas de séries temporais de imagens de satélite tem sido importante para mapear a cobertura da terra (ARVOR et al., 2011; BORGES; SANO,

2014; BENDINI et al., 2019). Especialmente para o caso das savanas, estudos prévios usando sensoriamento remoto com instrumentos de resolução espacial baixa a moderada, demonstraram o potencial do uso da dinâmica sazonal da vegetação para diferenciar fitofisionomias (FERREIRA; HUETE, 2004; RATANA et al., 2005). Esta possibilidade foi fortemente explorada por Schwieder et al. (2016), que usaram informações fenológicas derivadas de imagens Landsat a partir de componentes *Tasseled-cap* (TS) e do algoritmo TIMESAT para mapear savanas no Brasil. Os autores discutiram as limitações na análise dos dados, as quais foram principalmente associadas com: falhas na série temporal geradas da combinação de três instrumentos Landsat selecionados para melhorar a frequência de observações; a resolução espacial de 30 metros da série temporal Landsat; e a cobertura de nuvens. Os avanços da abordagem sazonal em relação à classificação utilizando uma data isolada não foram discutidos pelos autores. Ao mesmo tempo, concluíram que é possível mapear fitofisionomias savânicas utilizando suas diferenças fenológicas determinadas por componentes TC. Schwieder et al. (2016) salientaram a importância de se testar séries temporais densas e produzidas por instrumentos com resolução espacial mais refinada do que a produzida pelos sensores Landsat.

Neste contexto, o recente avanço das constelações de satélites, pequenos e padronizados, fornecem novas perspectivas para estudos da vegetação (BREUNIG et al., 2020; WANG et al., 2020; WU et al., 2021). Com capacidade de observação diária, a primeira geração da constelação de satélites PlanetScope (PS) (*Planet Labs Inc. Dove satellites*), por exemplo, é composta por mais de 180 CubeSats, com imagens adquiridas em quatro bandas espectrais largas (azul, verde, vermelho e infravermelho próximo) e com 3,7 metros de resolução espacial. Sua alta resolução temporal pode prover maior volume de imagens e, conseqüentemente, ampliar a probabilidade de se obter imagens livres de nuvens, que são um dos principais limitantes para o sensoriamento remoto óptico de ambientes tropicais (BENDINI et al., 2019). Usando dados PS, é possível calcular diferentes índices de vegetação (IVs) com sensibilidade distinta para atributos biofísicos das savanas como estrutura da vegetação, pigmentos e folhagem velha ou nova. Exemplos desses IVs são: *Normalized Difference Vegetation Index* (NDVI) (ROUSE et al., 1973), o *Enhanced Vegetation Index* (EVI) (HUETE et al., 2002), e o *Green-Red Normalized Difference* (GRND) (MOURA et al., 2017).

Para além disso, um estudo recente conduzido por Souza et al. (2021) na porção nordeste do bioma Cerrado, mostrou a importância de abordagens que fazem uso combinado de diferentes IVs (todos os IVs juntos em uma análise multivariada) para detectar distúrbios sobre áreas de savana. Essa estratégia possibilitou que os autores explorassem propriedades biofísicas das savanas que melhoraram a detecção de distúrbios, quando comparado ao uso individual de IVs. Baseado nessa investigação, o uso de uma estratégia de classificação a partir do uso combinado de IVs ou métricas *Land Surface Phenology* (LSP) determinadas de diferentes índices de vegetação, poderá ser útil para mapear as savanas no Brasil. No entanto, mais estudos são necessários para confirmar esta possibilidade.

Por combinar dados com densa série temporal e alta resolução espacial, satélites da constelação Planet podem potencializar a recuperação de métricas LSP calculadas de diferentes IVs sobre áreas de Cerrado. Os conjuntos de IVs ou métricas LSP resultantes podem ser usados como variáveis de entrada para classificar savanas, usando, por exemplo, o classificador Random Forest (RF). Este classificador é normalmente superior a outros classificadores em ambientes de Cerrado (TONIOL et al., 2017). A abordagem de uso combinado de IVs ou métricas LSP também deve ser testada para resolver os problemas de classificação decorrentes da heterogeneidade do bioma. Apesar destas possibilidades, na medida em que se sabe, dados PS nunca foram avaliados para a classificação de savanas no Brasil, tão pouco com base no uso combinado de IVs ou de métricas LSP calculadas a partir dos mesmos.

Inserido neste contexto, o tópico principal deste estudo é o possível uso de métricas fenológicas (LSP) determinadas de diferentes IVs (NDVI, EVI e GRND) de dados PS, como fonte de informação para melhorar a classificação das fitofisionomias do Cerrado.

1.1 Hipótese de trabalho

Testa-se a hipótese que métricas de fenologia da vegetação (LSP) aumentam a acurácia da classificação de fitofisionomias em uma área protegida de savana (Estação Ecológica de Águas emendadas – ESAE), quando comparadas à classificação feita com imagens obtidas durante a estação seca. Adicionalmente, verifica-se a hipótese da combinação de métricas LSP, reunidas de diferentes IVs (abordagem conjunta) com diferentes

sensibilidades à atributos biofísicos das savanas, melhorar a classificação da vegetação, quando comparada ao uso individual das métricas de cada IV.

1.2 Objetivos

1.2.1 Geral

Avaliar o desempenho de 12 métricas fenológicas calculadas de três diferentes IVs (NDVI, EVI e GRND) derivados de dados PS, para a classificação RF de oito fitofisionomias de Cerrado, utilizando as variáveis preditoras de forma individual ou combinada.

1.2.2 Específicos

- a) Analisar a resposta sazonal de fitofisionomias savânicas a partir de série temporal PS de NDVI, EVI e GRND, observando a variabilidade espacial das métricas LSP resultantes em comparação ao mapa de referência da vegetação disponível;
- b) Comparar o desempenho da classificação baseada em 12 métricas LSP, calculadas na estação de crescimento de 2017-2018, para cada IV no algoritmo *greenbrown*, contra o uso de IVs de 12 imagens PS obtidas na estação seca de 2017;
- c) Avaliar o desempenho na classificação RF do uso conjunto (todos os IVs ou métricas LSP) ou isolado (IVs ou métricas LSP usados separadamente) das variáveis de entrada.

2 FUNDAMENTAÇÃO TEÓRICA

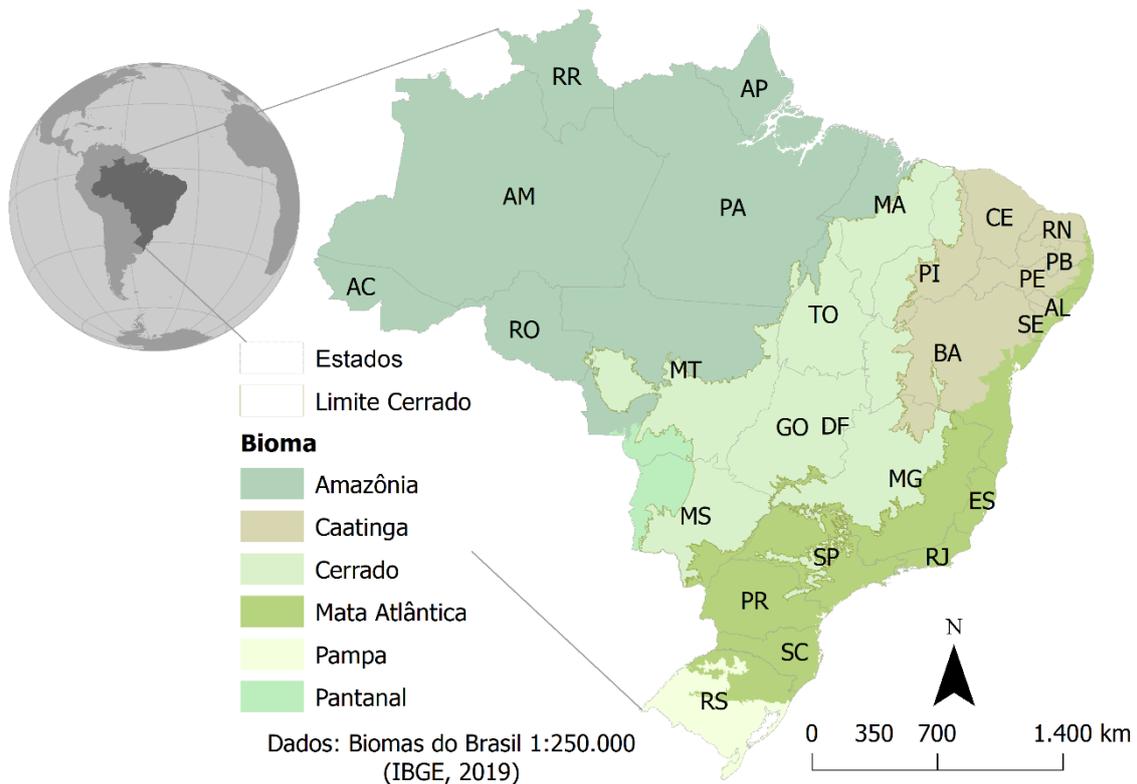
2.1 O bioma “Cerrado”

O domínio fitogeográfico de savana no Brasil é conhecido como Cerrado. Ele ocupa uma área equivalente a 23% do território nacional, com cerca de 2 milhões de km² (MALHEIROS, 2016; SANO et al., 2019). Isto lhe confere o título de segundo maior bioma do Brasil, depois do bioma Amazônico. Inserido na região do Planalto Central Brasileiro (AB’SABER, 1971), o Cerrado faz ecótono com os biomas Amazônia, Caatinga, Mata Atlântica e Pantanal (Figura 2.1). É classificado como um *hotspot* de biodiversidade (MYERS et al., 2000), devido ao alto grau de endemismo (PIVELLO, 2011a), ou seja, espécies da fauna e flora que ocorrem exclusivamente no Cerrado.

Com abrangência latitudinal, o Cerrado está sob influência do clima tropical úmido, com verão chuvoso e inverno seco, com forte sazonalidade. De modo geral, a estação chuvosa tem início no mês de outubro e se estende até abril, concentrando cerca de 90% da precipitação anual (WALTER, 1986). O período seco ocorre entre os meses de maio a setembro. Em média, a precipitação acumulada por ano alcança 1500 mm. No entanto, a precipitação no bioma varia de 600 mm a 2000 mm com gradiente de aumento de leste (transição com o bioma Caatinga) para oeste (transição com o bioma Amazônia) (SANO et al., 2019). A temperatura é amena na maior parte do bioma, com média anual entre 22°C e 27°C (RIBEIRO; WALTER, 1998; MALHEIROS, 2016).

O Cerrado se estende por 10 estados da federação e pelo Distrito Federal (Figura 2.1), sendo eles: Goiás e Tocantins, e em parte dos estados de Paraná, São Paulo, Piauí, Minas Gerais, Mato Grosso do Sul, Mato Grosso, Maranhão e Bahia. Sua ampla extensão resulta em condições geomorfológicas variadas (EITEN, 1987), além de tipos de solos distintos e formações fitofisionômicas associadas ao clima. O relevo é predominantemente plano ou suavemente ondulado (PIVELLO, 2011a), com altitude de 300 m a 1600 m. O tipo de solo predominante é o Latossolo (RIBEIRO; WALTER, 1998; EMBRAPA, 2003), ocorrendo em aproximadamente 86% de todo bioma (EMBRAPA, 2003), seguido de Neossolos Quartzarênicos, Argissolos e Plintossolos (EMBRAPA, 2003).

Figura 2.1 - Biomas do Brasil e estados de abrangência.



Fonte: Produção da autora.

As características do meio físico produzem uma alta diversidade de fitofisionomias que variam desde espécies gramíneas/herbáceas até arbustivas/arbóreas (MALHEIROS, 2016). De acordo com Ribeiro e Walter (1998), são descritos 11 tipos de fitofisionomias enquadradas em três grandes categorias de formações naturais: campestres (Campo Sujo, Campo Rupestre e Campo Limpo), savânicas (Cerrado stricto sensu, Parque de Cerrado, Palmeiral e Vereda) e florestais (Mata Ciliar, Mata de Galeria, Mata Seca e Cerradão) (Figura 2.2).

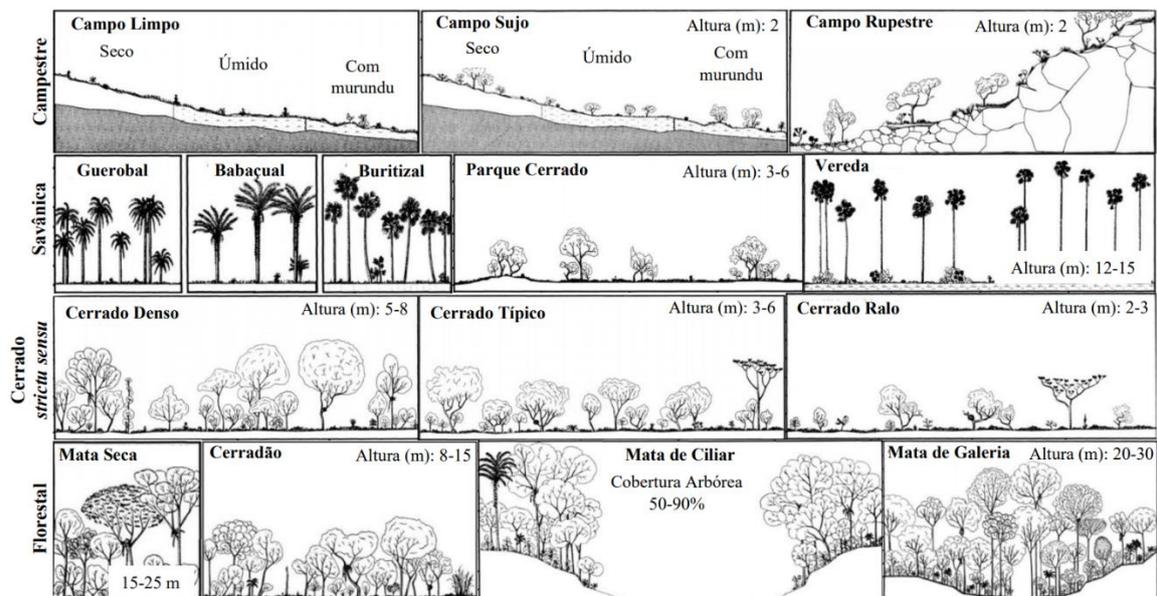
Formações Campestres reúnem Campo Limpo, Campo Sujo e Campo Rupestre. Campo Sujo é exclusivamente herbáceo-arbustivo, com arbustos e subarbustos esparsos entremeados no estrato herbáceo. Campo Rupestre aproxima-se do Campo Sujo, mas se difere pelo substrato composto por afloramentos rochosos e alto grau de endemismo florístico. Campo Limpo é predominantemente herbáceo, com ausência completa de árvores e presença de raros arbustos.

Formações Savânicas são compostas por Cerrado stricto sensu, caracterizado por árvores distribuídas de forma aleatória e com diferentes densidades sobre o terreno, com estratos

arbóreo e arbustivo-herbáceo. Parque Cerrado compreende formações com a presença de árvores agrupadas em pequenas elevações, conhecidas como “murundus”. A formação do tipo Palmeiral é marcada pela presença de uma única espécie de palmeira arbórea, enquanto a fitofisionomia Vereda é constituída de palmeira arbórea *Mauritia flexuosa* (buritis) sem dossel bem definido, circundada por Campo Limpo geralmente úmido.

Formações Florestais são compostas predominantemente por espécies arbóreas com dossel bem definido. As fitofisionomias Mata de Galeria e Mata Ciliar estão associadas aos cursos d’água, podendo a Mata de Galeria ser Inundável ou não-Inundável. Cerradão e Mata Seca se desenvolvem nos interflúvios, onde a Mata Seca apresenta três subtipos: Sempre-Verde, Semidecídua e Decidual.

Figura 2.2 - Gradiente de vegetação de formações naturais do Cerrado.



Fonte: Adaptado de Ribeiro e Walter (1998) e de Sano, Almeida e Ribeiro (2008).

A forte sazonalidade, marcada por um período chuvoso e outro seco, condicionou as espécies da flora do Cerrado a evoluírem e desenvolverem adaptações morfológicas e fenológicas para a sobrevivência. O ciclo vegetativo das plantas foi ajustado ao regime de chuva. Conseqüentemente, o padrão fenológico das espécies de plantas presentes em diferentes fitofisionomias tende a acompanhar a oscilação sazonal da precipitação (BERGAMASCHI, 2007; MALHEIROS, 2016).

Na paisagem, as fitofisionomias constituem um gradiente de vegetação que atua como sumidouro de gases do efeito estufa, com estoque de carbono expressivo nas formações

arbóreas e em biomassa subterrânea (BUSTAMANTE; OLIVEIRA, 2008; FERREIRA, 2003). Outra influência das formações naturais do Cerrado é no ciclo da água e na produção e distribuição de recursos hídricos pelo país (LIMA, 2011). Conhecido como o “berço das águas”, o bioma abriga nascentes que vertem para oito das doze regiões hidrográficas brasileiras. A contribuição mais relevante ocorre para as bacias do São Francisco, Parnaíba e Paraguai, cujo Cerrado é responsável por mais de 90% da vazão. Além disso, contribui com 21% da vazão do Atlântico Leste, 50% da região do Paraná e cerca de 60% de contribuição na região Tocantins-Araguaia (LIMA, 2011). O sistema radicular das plantas, a topografia e a porosidade do substrato rochoso favorecem o abastecimento de sistemas aquíferos existentes na região, regularizando a perenização dos corpos d’água superficiais (MALHEIROS, 2016).

Apesar da elevada importância do bioma para estabilidade de processos biogeoquímicos e seu alto grau de endemismo de espécies da fauna e da flora, as condições ambientais, como disponibilidade hídrica, solos quimicamente pobres com boa estrutura física e relevo plano, favorecem o avanço de atividades pecuárias e da agricultura mecanizada (PIVELLO, 2011a; SANO et al., 2019a). Apontadas como as principais causas de degradação e perda das savanas tropicais brasileiras, as mudanças no uso do solo levam a perda de solo por processos erosivos, perda de habitat pelo desmatamento e invasão de espécies exóticas, principalmente gramíneas africanas usadas para pastagens (KLINK; MACHADO, 2005; PIVELLO, 2011a; TRIGUEIRO; NABOUT; TESSAROLO, 2020; SOUZA, et al., 2020).

Outro elemento julgado como fator de degradação do Cerrado é o fogo. Quando utilizado de maneira desproporcional, ou seja, frequência e recorrência elevadas sobre alguns tipos de fitofisionomias, ele pode suprimir ecossistemas representativos do Cerrado, levando à mortalidade de árvores (FLORES et al., 2020). Muito comum para o manejo de áreas desmatadas e de pastagem (DURIGAN; RATTER, 2016), o regime inadequado do fogo na paisagem pode produzir incêndios descontrolados. Como consequência, se eliminam habitats, espécies vegetais não adaptadas ao fogo, afetando também os recursos hídricos (MARACAHIPES-SANTOS et al., 2020).

Cabe ressaltar que a ausência do fogo também é vista como um limitante para a persistência de espécies da flora do Cerrado. O ecossistema se desenvolveu na presença

de incêndios, dependendo deles para manter processos ecológicos (PIVELLO, 2011b; DANTAS; BATALHA; PAUSAS, 2013; DURIGAN; RATTER, 2016). No entanto, queimadas frequentes e severas causadas pelo homem têm o efeito contrário, produzindo degradação ambiental e o desenvolvimento de espécies invasoras. No período da seca, a precipitação em determinadas regiões do bioma pode ser inexistente, proporcionando ambiente altamente inflamável pelo acúmulo de biomassa seca (DURIGAN; RATTER, 2016).

No final da estação seca, sob máximo déficit hídrico, raios são fontes de ignição para incêndios naturais no Cerrado (PIVELLO, 2011b), que consomem a biomassa seca antes do brotamento de novos indivíduos. A vegetação possui adaptações ao fogo, como árvores que apresentam cascas espessas e resistentes (DANTAS; BATALHA; PAUSAS, 2013) e espécies em que o fogo atua na quebra de dormência (FIDELIS et al., 2019). Em ambientes onde o fogo é suprimido, pode ocorrer a substituição de formações savânicas por formações florestais, com aumento da densidade e área basal de espécies arbóreas (DURIGAN; RATTER, 2016), ocasionando a perda de ecossistemas campestres.

Em três décadas (1985-2017), a perda de vegetação natural florestal e não florestal do bioma para o avanço das atividades agrícolas foi de 33,8%, principalmente sobre áreas de savanas e formações de campo (SOUZA et al., 2020). De acordo com dados do PRODES Cerrado, operado pelo Instituto Nacional de Pesquisas Espaciais (FIP CERRADO, 2021), no período de agosto de 2020 a julho de 2021, a área de vegetação nativa suprimida do Cerrado foi de 8.531 km². Em comparação ao biênio anterior (2019/2020), foi verificado um aumento de 7,9% no desmatamento, no qual os estados do Maranhão, Tocantins e Bahia apresentaram as maiores áreas de supressão da vegetação, com 2.281 km², 1.710,55 km² e 925 km², respectivamente. Esses estados integram a mais nova fronteira agrícola no Cerrado, denominada MATOPIBA (abreviações dos Estados do Maranhão, Tocantins, Piauí e Bahia). O avanço agrícola nessa região surge como resultado da Moratória da Soja na Amazônia e de fatores locais no MATOPIBA como políticas de incentivo agrícola. Em conjunto, eles contribuíram para elevar as taxas de desmatamento no MATOPIBA em até 41%, na primeira década pós-moratória (SOUZA et al., 2020).

Esse cenário fez com que o Brasil assumisse o compromisso voluntário de reduzir o desmatamento no Cerrado na *United Nations Framework Convention on Climate Change*

em 2009. Entre as ferramentas para concretização do compromisso foi estabelecida a Política Nacional sobre Mudanças Climáticas (Lei nº 12.187/2009) e o Programa de Monitoramento Ambiental dos Biomas Brasileiros para o monitoramento da cobertura vegetal e detecção do desmatamento em tempo real. De forma complementar, o Brasil possui leis como a Lei nº12.651/2012, que dispõe sobre a proteção da vegetação nativa e o Sistema Nacional de Unidades de Conservação da Natureza (Lei nº 9.985/2000).

Atualmente apenas 11% da vegetação natural de Cerrado está delimitada como unidade de conservação de proteção integral ou uso sustentável nos níveis federal, estadual e municipal e terras indígenas (SANO et al., 2019). Em propriedades rurais, diretrizes de proteção da vegetação nativa estabelecem uma faixa mínima de vegetação natural no entorno de corpos d'águas (Área de Proteção Permanente) e área de Reserva Legal, sendo necessária a delimitação e uso sustentável de 35% de vegetação nativa de Cerrado no interior do imóvel rural.

De acordo com Sano et al. (2019), as áreas protegidas, principalmente na parte central e sul do bioma, compreendem locais menores e estão mais isoladas, o que as torna vulneráveis às pressões das atividades agropecuárias. Além disso, as mudanças climáticas globais podem alterar o regime de chuva quanto sua distribuição e duração (SANO et al., 2019), de forma a comprometer os processos ecológicos da vegetação adaptada à forte sazonalidade do bioma. Isto justifica a importância de estudos sobre o Cerrado brasileiro, incluindo a melhor compreensão da distribuição de suas fitofisionomias em áreas protegidas, tema abordado pelo presente trabalho.

2.2 Constelação de satélites PlanetScope (PS)

Em função do custo financeiro e das limitações acerca do tempo de revisita e da resolução espacial de sensores em satélites tradicionais como TERRA/AQUA, Landsat e Sentinel, o setor aeroespacial concentrou esforços na última década para o desenvolvimento de nanosatélites (NAGEL; NOVO; KAMPEL, 2020; SADEH, et al., 2021). Com alto desempenho de observação da Terra, os nanosatélites surgem do processo de miniaturização de tecnologias de sensores, sendo denominados CubeSats.

Esses sistemas são desenhados em pequenas dimensões com tamanho designado em unidade “U”, que equivale à 10 cm x 10 cm x 10 cm, e peso de aproximadamente 1,33 kg por U. Devido ao reduzido tamanho, conjuntos de CubeSats são lançados e constituem as

chamadas constelações de satélites, onde multi-sensores desempenham potencial de observação sem precedentes, com capacidade de fornecer imagens diárias com resolução espacial mais fina (<10 m) (HELDER, *et al.* 2020). O setor privado representa a iniciativa emergente no desenvolvimento, lançamento e operação de CubeSats, com destaque para a empresa americana Planet Labs fundada em 2010 (HOUBORG; MCCABE, 2018a). A Planet adquiriu a constelação de satélites RapidEye no ano de 2015 e finalizou as atividades desta constelação em março de 2020, após 11 anos de operação. Desde 2013, a empresa lançou cerca de 280 CubeSats (NAGEL; NOVO; KAMPEL, 2020) e atualmente opera a constelação SkySat (15 satélites com resolução espacial de 0,72 centímetros) e PlanetScope (PS) (PLANET TEAM, 2020).

A constelação PS é composta por mais de 180 CubeSats 3U (10 cm x 10 cm x 30 cm) que juntos apresentam capacidade de imageamento de 340 milhões de km² por dia (CHENG *et al.*, 2020; PLANET TEAM, 2020). Os sensores possuem visada ao nadir com largura de faixa de 24,6 km e resolução espacial de 3,7 m. A resolução radiométrica é de 12 bits (PLANET TEAM, 2020). São alocados em duas órbitas diferentes, sendo elas: órbita Estação Espacial Internacional, altitude de 400 km (inclinação de 51,6 °), com horário de cruzamento sobre o Equador variável e vida útil estimada de 1 ano (HOUBORG; MCCABE, 2018a; PLANET TEAM, 2020); e órbita Síncrona ao Sol, a 475 km da superfície (inclinação de 98 °), com passagem sobre o Equador entre 9:30 e 11:30 (horário solar local) e vida útil de aproximadamente 2-3 anos (HOUBORG; MCCABE, 2018a; PLANET TEAM, 2020).

À medida que os lançamentos foram realizados ao longo dos anos, a Planet Labs aprimorou os sensores. Alterações foram efetuadas principalmente na resolução espectral das bandas B (*Blue*), G (*Green*), R (*Red*) e NIR (*Near Infrared*). A partir de 2016 foram geradas cenas obtidas pela primeira geração de sensores da constelação PS (PS1) compostas pelas bandas RGB+NIR, cobrindo ampla faixa espectral: B (455-515 nm), G (500-590 nm), R (590-670 nm) e NIR (780-860 nm). Sensores da segunda geração (PS2), lançados a partir de 2018, ainda apresentam faixas espectrais amplas. No entanto, realizam o imageamento em novos comprimentos de onda, sendo eles: B (464-517 nm), G (547-585 nm), R (650-682 nm) e NIR (846-888 nm) (Tabela 2.1). Para a terceira geração (PS3), em operação a partir de 2020, as cenas são compostas por oito bandas cobrindo novas faixas espectrais.

Tabela 2.1 - Faixa espectral dos sensores PlanetScope da primeira (PS2 - 2016), segunda (PS2.SD - 2018) e terceira (PSB.SD - 2020) geração.

PS2		PS2.SD		PSB.SD			
<i>Banda</i>	λ (nm)						
B	455-515	B	464-517	CB	431-452*	Y	600-620*
G	500-590	G	547-585	B	465-515	R	650-680
R	590-670	R	650-682	GI	513-549*	RE	697-713*
NIR	780-860	NIR	846-888	GII	547-583	NIR	845-883

B: *Blue*, G: *Green*, R: *Red*, NIR: *Near Infrared*; CB: *Coastal Blue*, GI: *Green I*; GII: *Green II*; Y: *Yellow*; RE: *Red-Edge*; (*) indica novas faixas espectrais na terceira geração de sensores PlanetScope; (λ) Comprimento de onda em nanômetro.

Fonte: Produção da autora.

Três são os produtos disponibilizados pela empresa Planet Labs, derivados da constelação PS: a) Nível 1B (*PlanetScope Basic Scene Product*), refere-se ao produto de radiância no topo da atmosfera com correções de distorção óptica causada pelo sensor e co-registro das bandas espectrais, *pixel* variando de 3,7 – 4,1 metros dependendo da altitude do sensor; b) Nível 3B (*PlanetScope Ortho Scene Product*), produto de reflectância no topo da atmosfera ou reflectância da superfície, *pixel* de aproximadamente 3 metros, correções geométricas e radiométricas sobre efeitos da atmosfera com base no modelo de transferência radiativa 6SV2.1 e parâmetros recuperados de dados MODIS, projeção cartográfica Universal Transverse Mercator; c) Nível 3A (*PlanetScope Ortho Tile Product*), cena individual (25 x 25 km) produto de uma mescla de séries consecutivas de imagens individuais de um único satélite, com tamanho de *pixel* de 3,125 metros; correções radiométricas, imagens ortorretificadas e projetadas para projeção Universal Transversa de Mercator (UTM).

2.3 Fenologia da vegetação

A fenologia da vegetação descreve as fases ou estágios sazonais do ciclo de vida dos diferentes tipos de vegetação moldadas por padrões climáticos, desde o verdejamento, brotamento e floração até o desenvolvimento do dossel e senescência (KIMBALL, 2015). O evento que caracteriza a fenologia é o ciclo de crescimento resultante de processos fisiológicos, estruturais e funcionais da vegetação e suas interações com o meio. Devido

à forte influência dos aspectos climáticos, estes processos fornecem respostas acerca das mudanças das plantas em função das condições ambientais (GU et al., 2003).

Espacialmente complexos e temporalmente dinâmicos, os eventos fenológicos abarcam características intrínsecas à morfologia de espécies vegetais, assim como variações latitudinais microclimáticas. Em ecossistemas temperados, por exemplo, o ciclo fenológico coincide com as mudanças na duração do dia (disponibilidade de luz/energia). Em ambientes tropicais, a fenologia varia com a sazonalidade da precipitação e a estação seca (KIMBALL, 2015).

Da perspectiva do sensoriamento remoto, a observação remota dos eventos fenológicos é denominada fenologia da superfície terrestre (*Land Surface Phenology – LSP*) e permite descrever alterações em superfícies heterogêneas em larga escala (KIMBALL, 2015). O método adotado para derivação da LSP consiste na extração da curva sazonal de série temporal de índices de vegetação a partir de modelos matemáticos ou implementação de algoritmos (KIMBALL, 2015; ZENG et al., 2020). De forma geral, limiares são estabelecidos sobre a curva derivada dos IVs e parâmetros são calculados resultando em métricas fenológicas. Entre as métricas obtidas estão a definição do início da estação de crescimento, taxa de verdejamento (green up), pico da estação, início da senescência e duração da estação de crescimento (ZENG et al., 2020).

2.3.1 PlanetScope e fenologia da vegetação

No que tange às avaliações acerca do uso da fenologia da vegetação a partir de dados PlanetScope, alguns estudos vêm sendo desenvolvidos. Cheng et al. (2020) verificaram que a série temporal de imagens PS foi suficiente para obter métricas fenológicas por meio do NDVI, quando comparada aos dados obtidos por fotografia digital e ao produto NDVI do MODIS (Moderate Resolution Imaging Spectrometer), em área de pastagem no Kenya. Wang et al. (2020) observaram, com base na estimativa da cobertura de vegetação verde e da vegetação não-fotossinteticamente ativa, que dados da estação seca oriundos da constelação PS permitiram detectar com precisão mudanças sazonais na reflectância espectral em nível de ecossistema e dossel individual para sítios localizados na floresta Amazônica.

Myers et al. (2019) analisaram o impacto da frequência de imagens PS no ajuste do modelo e estimativa do tempo de transição fenológica na estação de crescimento de 2018-2019 em culturas de milho. Os autores verificaram um dia de erro adicionado para cada aumento de três dias no intervalo de amostragem temporal. Eles observaram alteração drástica nos parâmetros de ajuste e forma da curva do índice de vegetação NDVI quando se adotou menos pontos de amostragem, tornando as estimativas do tempo de transição da fenologia menos precisas.

A fenologia de florestas temperadas também foi explorada para séries de EVI e NDVI, comparando-se a resposta da vegetação do PS com a observada localmente por fenocâmeras (WU et al., 2021). Uma análise sobre a floração de espécies silvestres em um parque nacional localizado no hemisfério norte, com base em dados PS, Sentinel e Landsat, demonstrou que os dados PS capturaram a época da floração com precisão de 70% (JOHN et al., 2020). Quando integrado à outras fontes de dados, a precisão apresentou um ganho de 7%. Os autores ainda ressaltaram os ganhos com a alta resolução espacial dos dados PS e alertaram para a irregularidade da qualidade radiométrica dos dados, compensada nesse trabalho a partir da integração com dados de satélites de maior qualidade radiométrica (JOHN et al., 2020).

2.4 Índice de Vegetação (IVs)

Índices de Vegetação são comumente utilizados para extrair e modelar características bioquímicas, fisiológicas e estruturais da vegetação, com base em operações aritméticas que levam em consideração a reflectância em diferentes faixas espectrais (ZANOTTA; FERREIRA; ZORTEA, 2019). Em ecossistemas terrestres, como o bioma Cerrado, dados multiespectrais de sensoriamento remoto orbital possibilitam a análise da vegetação em nível de dossel.

Em sua maioria, as regiões do espectro eletromagnético do visível (*Red* 600-700 nm) e do infravermelho próximo (*NIR* 700-900 nm) são empregadas no cálculo de IVs. Isso ocorre devido ao comportamento antagônico da reflectância nessas faixas espectrais (PONZONI; SHIMABUKURO; KUPLICH, 2012). A absorção da energia eletromagnética é elevada em aproximadamente 680 nm (baixa reflectância) devido a pigmentos fotossintetizantes. Na região do NIR, a reflectância é alta em decorrência do maior espalhamento de fótons pelo mesófilo localizado na estrutura celular das folhas

(PONZONI; SHIMABUKURO; KUPLICH, 2012; SANO et al., 2019c). Com base no potencial e sensibilidade para revelar diferentes características da vegetação, como conteúdo de pigmentos fotossintetizantes, estrutura da vegetação e desenvolvimento de folhagem nova, alguns exemplos de IVs são: *Normalized Difference Vegetation Index* (NDVI), *Enhanced Vegetation Index* (EVI) e o *Green-Red Normalized Difference* (GRND).

O NDVI, proposto por Rouse et al. (1973), originou-se da normalização do índice *Simple Ratio* para o intervalo de -1 a 1. Amplamente utilizado, o perfil temporal do NDVI possibilita a análise sobre atividades sazonais e fenológicas, duração do período de crescimento, pico verde e mudanças fisiológicas (PONZONI; SHIMABUKURO; KUPLICH, 2012), demonstrando sensibilidade às variações na biomassa e no conteúdo de clorofila. Entretanto, em áreas com elevado adensamento de biomassa, o NDVI pode apresentar rápida saturação a partir de determinado estágio de desenvolvimento (PONZONI; SHIMABUKURO; KUPLICH, 2012; SANO et al., 2019c; ZANOTTA; FERREIRA; ZORTEA, 2019). O cálculo do NDVI é apresentado na Equação 2.1, com respectivas bandas dos sensores da constelação PlanetScope.

$$NDVI = \frac{(\rho NIR_{b4} - \rho Red_{b3})}{(\rho NIR_{b4} + \rho Red_{b3})} \quad (2.1)$$

Onde ρ refere-se à reflectância dos canais espectrais da constelação PS, *NIR* (banda 4), *Red* (banda 3).

Idealizado para minimizar os problemas de saturação do NDVI em áreas com vegetação densa e reduzir o efeito do solo na observação de vegetação esparsa, o EVI foi proposto por Huete et al. (1997). Refere-se a um índice não normalizado que baseia seu cálculo nas regiões do *Blue*, *Red* e *NIR*. Assim, é sensível a estrutura do dossel da vegetação porque é fortemente influenciado pela resposta do NIR. A Equação 2.2 apresenta a formulação matemática para obter o índice EVI. Como pode ser observado um fator de ganho de ajuste (2,5) é aplicado, junto ao fator de substrato (L), para reduzir efeitos do solo (HUETE et al., 2002). De forma complementar, fatores de compensação do espalhamento atmosférico ocasionado por aerossóis (C1 e C2) são aplicados, a partir do uso da banda *Blue* para corrigir a banda *Red*.

$$EVI = 2,5 \times \left(\frac{\rho NIR_{b4} - \rho Red_{b3}}{\rho NIR_{b4} + C_1[\rho Red_{b3}] - C_2[\rho Blue_{b1}] + L} \right) \quad (2.2)$$

Onde ρ é a reflectância dos canais espectrais da constelação PS, *NIR* (banda 4), *Red* (banda 3) e *Blue* (banda 3). Os fatores e seus valores empíricos são: $L = 0,5$; $C_1 = 6$; $C_2 = 7,5$.

O GRND, formulado por Moura et al. (2017), consiste em um índice que baseia seu cálculo apenas em bandas situadas na região do visível do espectro eletromagnético (*Green e Red*) (Equação 2.3). O GRND foi proposto para monitorar a perda e brotamento de folhas novas com base na resposta espectral da região do *Green*, obtendo parâmetros acerca da condição de fitossanidade da vegetação (MOURA et al., 2017).

$$GRND = \left(\frac{\rho Green_{b2} - \rho Red_{b3}}{\rho Green_{b2} + \rho Red_{b3}} \right) \quad (2.3)$$

onde ρ é a reflectância dos canais espectrais da constelação PS, *Green* (banda 2), *Red* (banda 3).

2.5 Algoritmo Greenbrown

O algoritmo *Greenbrown* foi desenvolvido por FORKEL et al. (2013) para ser aplicado na linguagem de programação R (<http://greenbrown.r-forge.r-project.org/>), reunindo diferentes funções de análise sobre séries temporais. As duas grandes funcionalidades do algoritmo se dividem em análise de tendência/ponto de interrupção e derivação da fenologia da vegetação (FORKEL et al., 2015). O algoritmo inclui métodos de preparação da série temporal como suavização e interpolação.

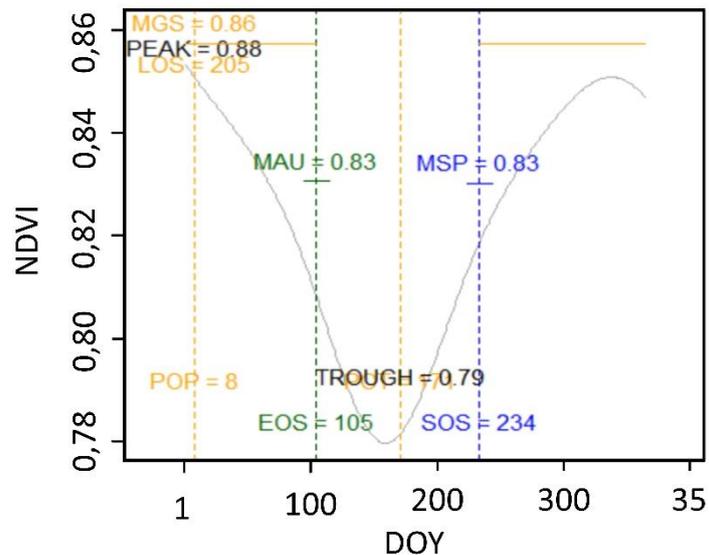
A função de análise fenológica permite detectar o ciclo sazonal de desenvolvimento da vegetação e a extração de métricas de séries temporais de IVs (FORKEL; WUTZLER, 2015), sendo elas (Figura 2.3): SOS (início da estação), EOS (final da estação), LOS (comprimento da estação), POP (posição do valor máximo), POT (posição do valor mínimo), MGS (valor médio da estação de crescimento), PEAK (valor de pico), TRG (valor mínimo), MSP (valor médio da primavera), MAU (valor médio do outono), RSP (taxa de *green up* na primavera) e RAU (taxa de senescência no outono).

Entre as métricas descritas, SOS consiste no ponto no tempo (*Day of the year - DOY*) cujo índice de vegetação apresenta fase ascendente, representando o início da estação de

crescimento ou a fenologia na primavera (CAPARROS-SANTIAGO; RODRIGUEZ-GALIANO; DASH, 2021). EOS compreende o final da estação (DOY) extraído da fase descendente e relacionado à fase de senescência ou fenologia do outono (CAPARROS-SANTIAGO; RODRIGUEZ-GALIANO; DASH, 2021). Ambas as métricas, SOS e EOS, são calculadas pelo *Greenbrown* considerando os limites de 50% da curva de verdejamento, a derivada da curva sazonal ou limiares estabelecidos pelo analista (FORKEL; WUTZLER, 2015).

A partir de SOS e EOS, as demais métricas fenológicas são calculadas. LOS refere-se à extensão temporal do período de desenvolvimento vegetativo das plantas (CAPARROS-SANTIAGO; RODRIGUEZ-GALIANO; DASH, 2021), ou seja, o comprimento da estação entre SOS e EOS representado em dias. O dia em que ocorre a máxima (POP) e mínima (POT) atividade fotossintética da vegetação é expresso por valores de IV (PEAK e TRG, respectivamente) em determinado DOY. O valor médio de IV na primavera (MSP) corresponde ao meio da temporada de crescimento, na posição central da curva ascendente. Para a estação de outono, o valor de IV na posição central da curva descendente representa MAU e consiste no valor médio de IV no período de senescência. A amplitude do IV mínimo e médio na primavera expressa a taxa de *green up* (RSP), enquanto RAU consiste na amplitude entre o IV médio no outono e IV mínimo, caracterizando a taxa de senescência.

Figura 2.3 - Métricas fenológicas derivadas do ciclo de crescimento da vegetação a partir do algoritmo Greenbrown.



Descrição: A linha cinza representa a curva do ciclo de crescimento extraída da série temporal de índice de vegetação; em azul, métricas derivadas da curva ascendente (SOS e MSP) e em verde métricas da curva descendente (EOS e MAU) do ciclo de crescimento; em preto são representadas as métricas de máxima (PEAK) e mínima (TROUGH) atividade fotossintética; em amarelo as métricas que sintetizam a duração do ciclo de crescimento (LOS), valor médio do IV durante a estação (MGS) e os dias de máxima (POP) e mínima (POT) atividade fotossintética.

Fonte: Adaptado de Forkel e Wutzler (2015).

Além disso, o algoritmo disponibiliza funções de preenchimento de lacunas na série temporal, suavização e interpolação para periodicidade diária. A interpolação é linear e a suavização é feita utilizando uma janela mediana. Outra opção é o preenchimento e suavização a partir da análise de espectro singular unidimensional e o ajuste para cada ano de uma função logística dupla (FORKEL; WUTZLER, 2015).

2.6 Random Forest (RF)

O RF é um algoritmo de aprendizagem de máquina (*Machine Learning*) supervisionado, isto é, utiliza-se de dados rotulados para o treinamento de modelos (ZANOTTA; FERREIRA; ZORTEA, 2019). Ele se baseia em árvores de decisão para fins de classificação ou regressão. Amplamente utilizado na comunidade de sensoriamento remoto (TONIOL et al., 2017; SOUZA MENDES et al., 2019), RF é um classificador não-paramétrico. Muitas vezes, dados derivados de sensoriamento remoto não

apresentam distribuição normal, condição exigida por classificadores paramétricos. Posto isto, suposições acerca da distribuição e frequência dos dados não são atendidas, sendo adotados classificadores não paramétricos como *Classification and Regression Tree*, *Support Vector Machine* e RF (BELGIU; DRAGUT, 2016).

Para a construção das árvores de decisão, dois parâmetros precisam ser definidos: o número de árvores de decisão a serem geradas (*tree*) e número de variáveis a serem selecionadas e testadas para a melhor divisão durante o crescimento das árvores (*try*) (BELGIU; DRAGUT, 2016). A maioria dos trabalhos em SR utilizam o valor 500 devido à estabilização dos erros ocorrer antes que este número de árvores seja alcançado (GISLASON; BENEDIKTSSON; SVEINSSON, 2006). Além disso, pacotes desenvolvidos para aplicação do RF utilizam o valor empírico de *tree* 500, como é o caso do “*randomForest*” aplicado no software R (LIAW; WIENER, 2002). O parâmetro *try*, por sua vez, é obtido através da raiz quadrada do número de variáveis de entrada e pode aumentar o tempo computacional, pois o algoritmo calcula o ganho de informação por todas as variáveis utilizadas para dividir os nós (BELGIU; DRAGUT, 2016).

A construção de uma RF ocorre sobre o nó inicial, que contém o conjunto total de variáveis (amostras) divididas em amostras de treinamento e validação. O treinamento do algoritmo é realizado com base na aleatorização das variáveis treino que dão origem aos nós, compondo subconjuntos de decisão. Para cada subconjunto, um teste é realizado sobre cada variável e, em função do ganho de informação, a melhor variável é escolhida, dando origem aos ramos da árvore.

As árvores crescem sem poda e o mesmo procedimento é realizado até o enésimo subconjunto, originando um número x de árvores (conjunto de classificadores) que formam uma floresta.

A classificação final é feita sobre um sistema cujo comportamento de várias variáveis em associação levam a determinar a qual classe determinação combinação de variáveis representa. O erro associado a classificação do RF depende da correlação entre as árvores e a taxa de acerto de cada árvore (BREIMAN, 2001). A seleção aleatória de variáveis para cada nó produz árvores diferentes (diminuindo a correlação) e a força individual de cada árvore será maior sobre a taxa de acerto, reduzindo o erro de classificação.

A análise sobre os atributos baseia-se no processo de descoberta de impurezas nos dados, a fim de revelar qual a variável que melhor separa as classes. Essa avaliação poder ser realizada a partir de medidas de homogeneidade, entre elas o índice de Gini. Sobre cada variável utilizada para gerar uma nova divisão do nó, o índice Gini é então calculado e comparado ao nó original, com resultado variando de 0 (homogêneo) a 1 (heterogêneo). Ao final do processo de classificação, os menores índices Gini da divisão dos nós são somados para cada variável de entrada, obtendo como resultado os maiores valores do índice Gini geral (Mean Decrease Gini) associado aos nós com maior pureza de classificação (BREIMAN, 2001).

3 ÁREA DE ESTUDO

Localizada no município de Planaltina-DF, a Estação Ecológica de Águas Emendadas (ESAE) encontra-se a 50 km do centro da cidade de Brasília (JACON et al., 2017), entre os paralelos 15°31'S e 15°36'S e os meridianos 47°32'O e 47°40'O. Criada em 1968 como Reserva Biológica de Águas Emendadas (Decreto nº 771, de 12 de agosto de 1968), ela foi elevada à Estação Ecológica em 1988, pelo Decreto nº 11.137 de 16 de junho de 1988 (ALBUQUERQUE, 2008). Segundo o Sistema Nacional de Unidades de Conservação, a categoria de unidade de conservação Estação Ecológica enquadra-se no grupo das Unidades de Proteção Integral, cujo objetivo é preservar a natureza e garantir a manutenção dos ecossistemas livres de alterações antrópicas. Admite-se apenas o seu uso indireto para realização de pesquisas científicas e atividades de educação ambiental (BRASIL, 2000).

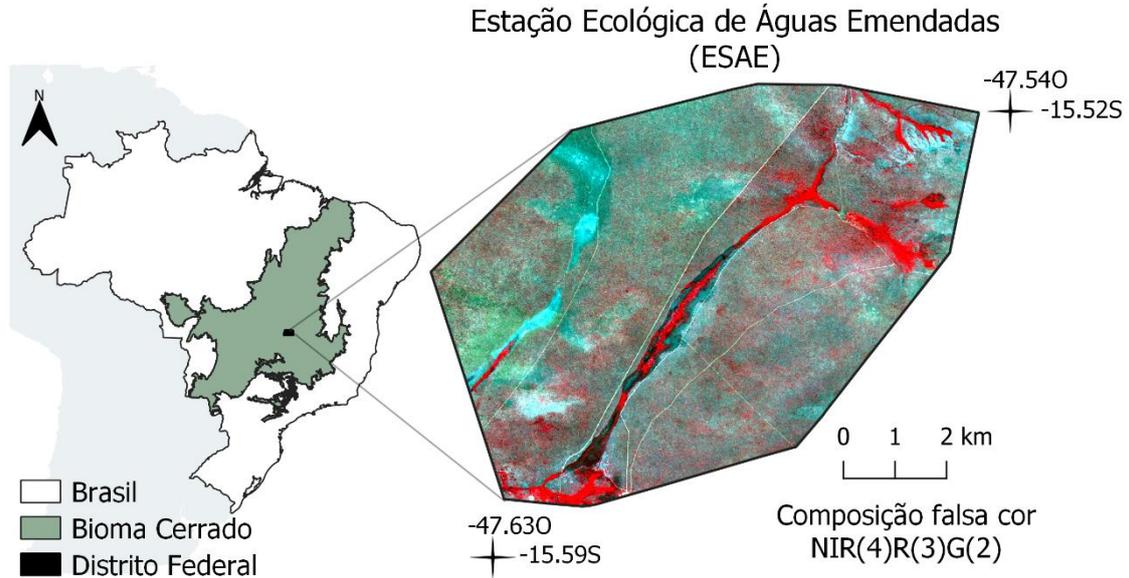
Atualmente, o limite territorial da ESAE possui um polígono principal e uma área adjacente referente à Lagoa Bonita (BERLINCK, 2008), que estão sob responsabilidade do Instituto Brasília Ambiental. Apresenta uma área equivalente a 10.547 hectares. Para este trabalho será considerado como alvo de análise uma área equivalente a 6254.96 hectares localizada no perímetro principal (Figura 3.1).

De acordo com Maia e Baptista (2008), o relevo é plano com altitude média entre 1.000 e 1.200 metros (MAIA; BAPTISTA, 2008). Dentre os grupos de solo predominante na ESAE estão os Latossolo Vermelho, Latossolo Vermelho-Amarelo, Gleissolo Háplico, Cambissolo Háplico e Neossolo Quartzarênico (LACERDA, 2008). Com base na classificação climática de Köppen, o clima da região é do tipo Cwa (tropical de altitude) com temperatura média variando entre 18°C e 22°C e chuva de verão e seca de inverno.

Como pode ser observado na Figura 3.2, que reúne dados da estação automática A045 do Instituto Nacional de Meteorologia (INMET) localizada na ESAE, o maior volume de precipitação concentra-se entre os meses de outubro e abril. O período seco se inicia em maio e estende-se até setembro, onde a precipitação permanece abaixo de 80 mm. A precipitação média anual é de cerca de 1.552 mm, com forte sazonalidade, enquanto as temperaturas máxima, média e mínima são de 30°C, 21°C e 16°C, respectivamente. O período seco coincide com o inverno, quando as chuvas são praticamente inexistentes. O

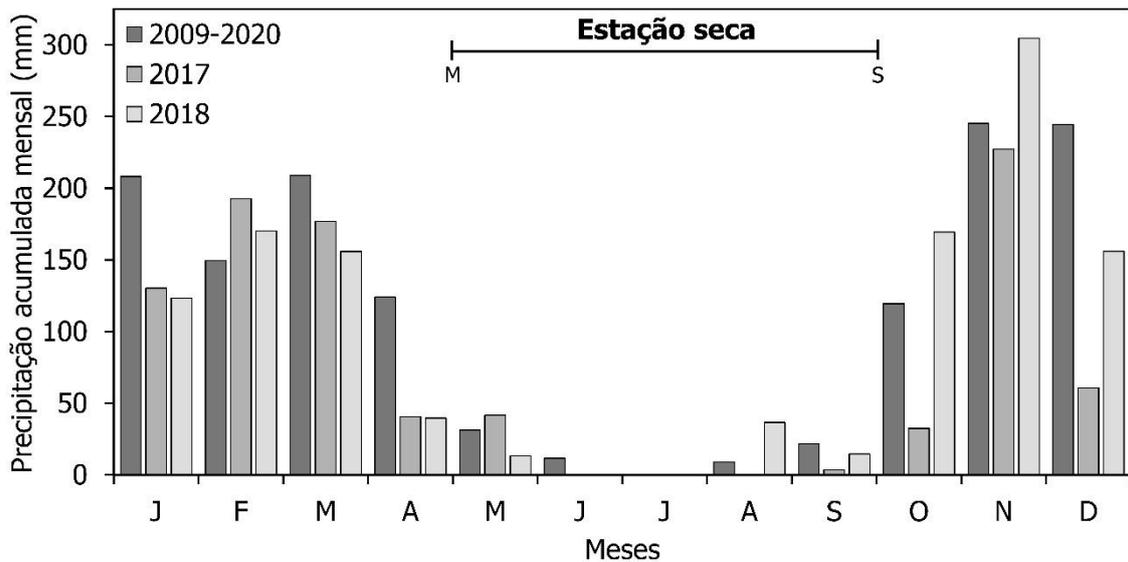
mês de julho compreende a época com menor volume de precipitação, apresentando as menores temperaturas (EMBRAPA, 1978).

Figura 3.1 - Localização da Estação Ecológica de Águas Emendadas (ESAE) no bioma Cerrado. Uma composição falsa-cor da constelação de satélites PlanetScope é mostrada com as bandas 4(NIR), 2(G) e 1(B) exibidas em RGB, respectivamente.



Fonte: Produção da autora.

Figura 3.2 - Precipitação acumulada mensal em 2017 e 2018 comparada ao padrão médio da precipitação no período de 2009 a 2020. Os dados foram medidos pela estação meteorológica automática A045 do Instituto Nacional de Meteorologia (INMET). A estação seca (maio a setembro) é indicada na parte superior.



Fonte: Produção da autora.

A ESAE, junto ao Parque Nacional de Brasília e as unidades de conservação de Área de Proteção Ambiental (APA) Gama e APA Cabeça de Veado no Distrito Federal, constituem a Zona-Núcleo da Reserva da Biosfera do Cerrado (UNESCO, 2000). Essa zona foi estabelecida devido ao mosaico representativo de vegetação do tipo Cerrado que as unidades de conservação abrigam. A ESAE possui rica diversidade florística e de fitofisionomias savânicas, altamente representativas do Cerrado, que vão desde campos abertos a formações florestais densas (MUNHOZ; RIBEIRO, 2008; FELFILI et al., 2007).

Descritas por Ribeiro e Walter (1998) e inventariadas por Jacon et al. (2017), a ESAE contém fitofisionomias campestres (Campo Limpo, Campo Sujo e Campo Cerrado), savânicas (Cerrado *Stricto Sensu* Ralo, Típico e Denso, e Veredas) e florestais (Mata de Galeria). Entre as formações do tipo campestre, Campo Limpo (CL) é formado predominantemente por estrato herbáceo, com raros arbustos e ausência completa de árvores. Campo Sujo (CS) refere-se à vegetação exclusivamente herbáceo-arbustivo, com arbustos e subarbustos esparsos, em sua maioria constituído por indivíduos menos desenvolvidos das espécies arbóreas. O Campo Cerrado (CC), classe adaptada de Campo Rupestre, consiste em fitofisionomia predominantemente herbáceo-arbustivo, com eventual presença de árvores pouco desenvolvidas que atingem até dois metros de altura. Abrange um complexo de vegetação que agrupa paisagens em micro-relevos com espécies típicas, ocupando trechos de afloramentos rochosos.

O tipo de formação Cerrado *stricto sensu* compreende a presença de árvores baixas, inclinadas, tortuosas, com ramificações irregulares e retorcidas. Arbustos e subarbustos encontram-se espalhados, com algumas espécies apresentando órgãos subterrâneos perenes, com indivíduos de espécies que possuem raízes profundas que não sofrem restrição hídrica durante a estação seca. As espécies lenhosas, em geral, possuem folhas rígidas e com texturas de “couro” que se quebram facilmente e são adaptadas às condições de seca. Indivíduos arbustivos e subarbustivos adaptados ao fogo apresentam rebrota após eventos de queima ou corte. No período chuvoso, camadas arbustivas e herbáceas apresentam rápido crescimento. Fatores como clima, duração da estação chuvosa e fertilidade do solo condicionam as subdivisões de fitofisionomias. As formações presentes no ESAE incluem: Cerrado Ralo (CR), subtipo de vegetação arbóreo-arbustivo, com cobertura arbórea de 5% a 20% e altura média de dois a três metros. Representa a

forma mais baixa e menos densa de Cerrado stricto sensu; Cerrado Típico (CT), vegetação predominantemente arbóreo-arbustivo, com cobertura arbórea de 20% a 50% e altura média de três a seis metros. É a forma comum e intermediária entre o Cerrado Denso e o Cerrado Ralo; e Cerrado Denso (CD), vegetação predominantemente arbórea, com cobertura de 50% a 70% e altura média de cinco a oito metros. É a forma mais densa e alta de Cerrado, com arbustos e estrato herbáceo mais ralos.

A formação do tipo Vereda (VE) é composta por palmeiras arbórea *Mauritia flexuosa* (Buritis) que não formam dossel, altura média de 12 a 15 metros e cobertura entre 5% e 10%. Ocorrem em meio a agrupamentos mais ou menos densos de espécies arbustivo-herbáceas circundadas por campo limpo geralmente úmido. Ocupam os vales ou áreas planas com drenagem mal definida, comuns em regiões próximas às nascentes ou na borda de matas de galeria. Sua ocorrência condiciona-se ao afloramento do lençol freático.

A Mata de Galeria (MG) consiste em vegetação florestal com presença permanente das folhas (perenifólia) durante o ano todo, não apresentando queda acentuada das folhas durante a estação seca. Acompanha os rios de pequeno porte e córregos, formando dossel fechado (galeria) sobre o curso d'água, com altura média do estrato arbóreo entre 20 e 30 metros, superposição de copas, com regiões inundáveis (lençol freático está próximo ou sobre a superfície na maior parte do ano, mesmo na estação seca) e não-inundáveis (lençol freático não está próximo ou sobre a superfície na maior parte do ano).

A Tabela 3.1 contém informações sintetizadas sobre as fitofisionomias que ocorrem na área da ESAE, em conformidade ao proposto por Ribeiro e Walter (1998) e ao inventário florestal realizado durante campanha de campo por Jacon et al. (2017), assim como respectivos tipos de solo em que ocorrem. A Figura 3.3 apresenta o comportamento das fitofisionomias em uma imagem falsa cor e nos índices de vegetação (NDVI, EVI e GRND). De forma complementar, a Figura 3.4 reuni fotografias obtidas em campo na ESAE de cada fitofisionomia considerada nessa dissertação.

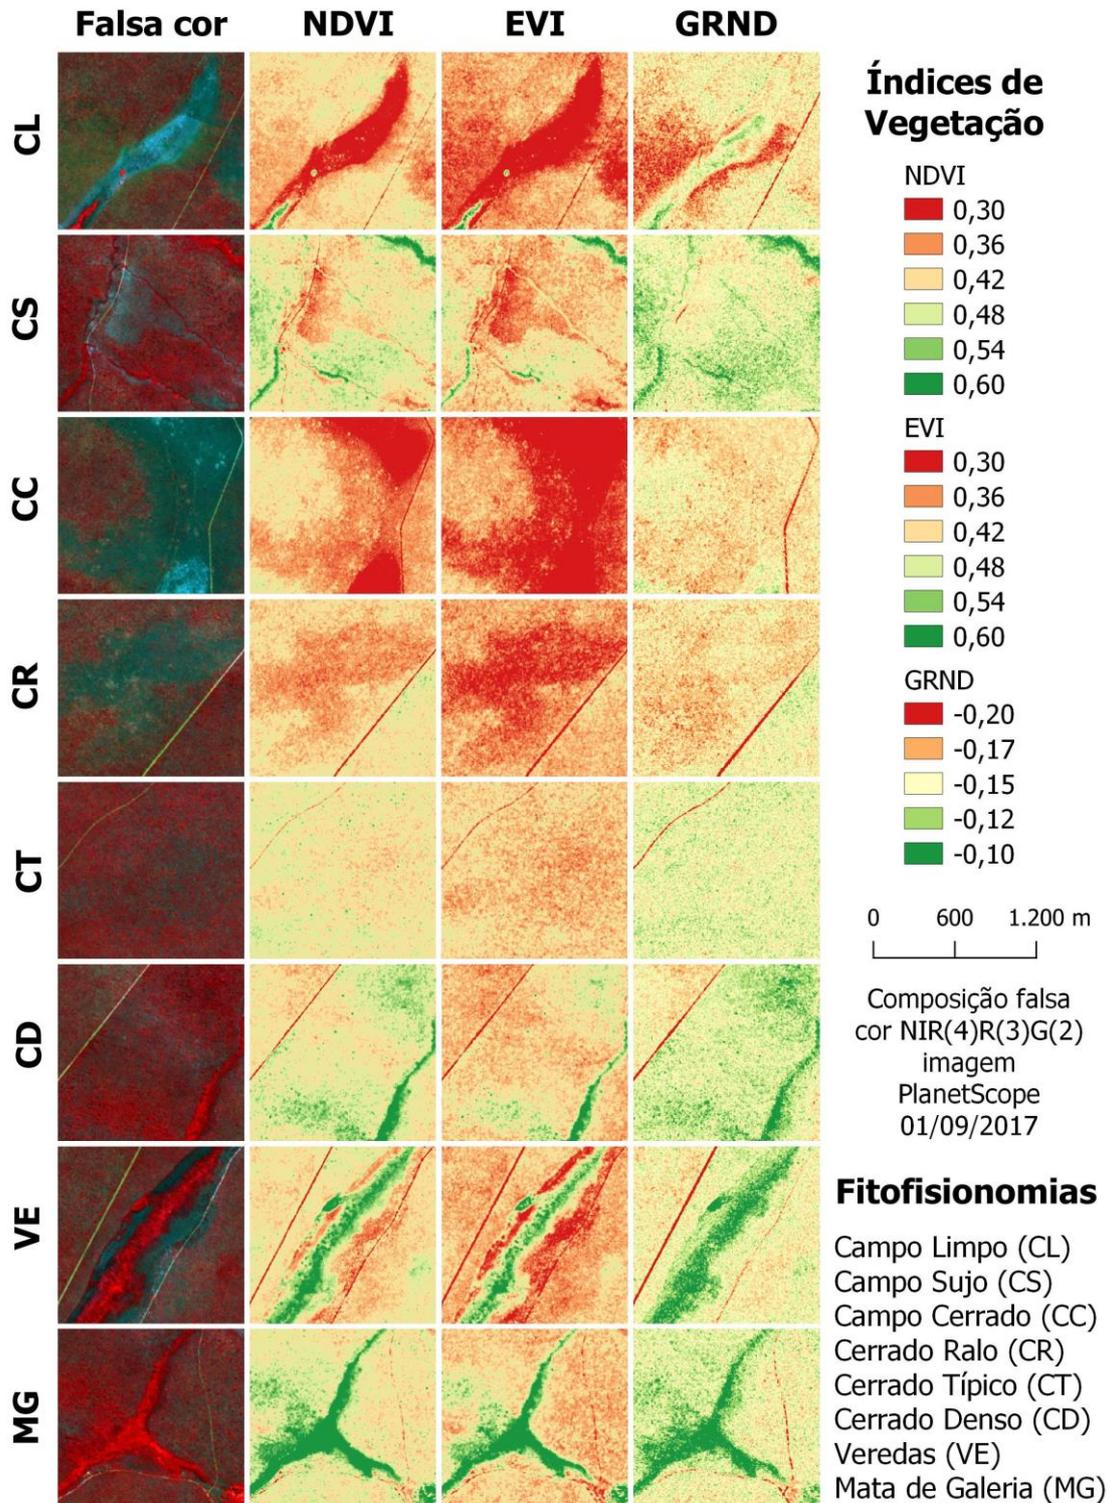
Tabela 3.1 - Características das fitofisionomias e tipo de solo em que ocorrem, na Estação Ecológica de Águas Emendadas (ESAE).

Fitofisionomia	Características da paisagem	Cobertura arbórea (%)	Altura média das árvores (m)	Tipo de solo
CL	Campo aberto, ausência de árvores e predominantemente herbáceo com raros arbustos	< 1	-	Latossolo Vermelho-Amarelo
CS	Exclusivamente herbáceo-arbustivo, com arbustos e subarbustos esparsos	< 5	2	Latossolo Vermelho-Amarelo e Cambissolos Háplicos
CC	Eventual presença de árvores, predominantemente herbáceo-arbustivo	5-20	2-3	Latossolo Vermelho-Amarelo
CR	Subtipo de vegetação arbórea-arbustiva, forma mais baixa e menos densa de Cerrado Stricto Sensu	5-20	2-3	Latossolo Vermelho e Neossolos Quartzarênico
CT	Vegetação arbóreo-arbustivo	20-50	3-6	Latossolo Vermelho
CD	Vegetação arbórea, com arbustos e estrato herbáceo mais ralo	50-70	5-8	Latossolo Vermelho
VE	Composta por palmeira arbórea Buritis, não formam dossel	5-10	12-15	Gleissolos Háplicos
MG	Vegetação densa, sempre verde, principalmente ao longo de cursos d'água	40-70 na estação seca; 50-90 na estação chuvosa	20-30	Gleissolos Háplicos e Latossolo Vermelho-Amarelo

Abreviações: CL (Campo Limpo); CS (Campo Sujo); CC (Campo Cerrado); CR (Cerrado Ralo); CT (Cerrado Típico); CD (Cerrado Denso); VE (Veredas); e MG (Mata de Galeria).

Fonte: Adaptado de Ferreira (2003); Sistema de classificação e valores proposto por Ribeiro e Walter (1998).

Figura 3.3 - Fitofisionomias de Cerrados presentes na ESAE representadas por imagens PlanetScope Falsa Cor (4-3-2) e índices de vegetação NDVI, EVI e GRND. As imagens foram adquiridas em 01/09/2017.



Fonte: Produção da autora.

Figura 3.4 - Registros fotográficos das fitofisionomias da ESAE.



Abreviações: CL (Campo Limpo); CS (Campo Sujo); CC (Campo Cerrado); CR (Cerrado Ralo); CT (Cerrado Típico); CD (Cerrado Denso); VE (Veredas); e MG (Mata de Galeria).

Fonte: Jacon et al. (2017).

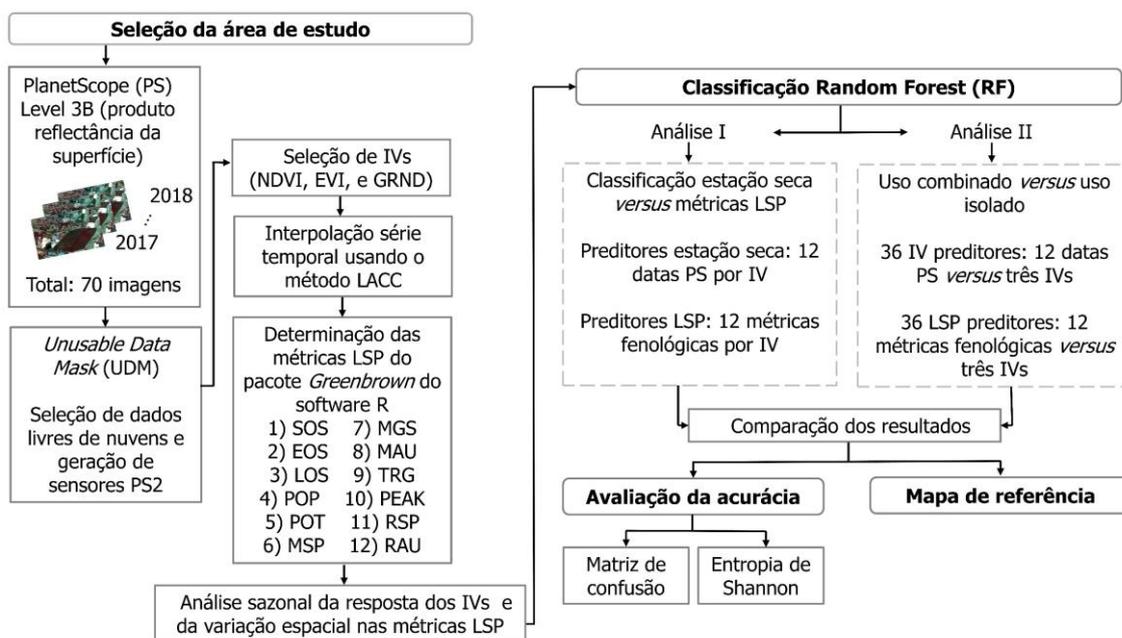
Outro fator que eleva a relevância ecológica da ESAE refere-se as duas nascentes em seu interior, que vertem para duas grandes bacias continentais. Este fenômeno originou o nome de Águas Emendadas. Na área de ocorrência da formação savânica Vereda, nascem os córregos Vereda Grande e Brejinho, que vertem para a região norte e sul, respectivamente. As águas que drenam para o norte irão abastecer a Bacia Hidrográfica do Rio Maranhão, contribuindo para a formação dos corpos hídricos da Bacia Hidrográfica Tocantins/Araguaia. O córrego Brejinho, por sua vez, drena suas águas para o sul. Este córrego contribui para a formação do rio São Bartolomeu, o qual dará origem a formação dos corpos hídricos da Bacia Hidrográfica do Rio Paraná.

O avanço da atividade agrícola no entorno da ESAE, principalmente dedicada a produção de grãos de soja, associada ao adensamento populacional que impulsiona o crescimento da cidade de Planaltina-DF, exerce pressões sobre a conservação da ESAE (REZENDE; PAPA, 2008). Em virtude disso, e corroborando para o objetivo de sua criação de promover pesquisas, diversos estudos foram desenvolvidos na ESAE (FELFILI et al., 2007; BERLINCK, 2008; RIBEIRA; ROCHA; MARINHO, 2011; JACON et al., 2017; JACON et al., 2021). O objetivo destes estudos é contribuir para a conservação do bioma Cerrado e proteger espécies endêmicas e serviços ambientais prestados pela ESAE, como o fornecimento de água.

4 METODOLOGIA

Os procedimentos metodológicos adotados para a classificação das fitofisionomias de Cerrado são apresentados na Figura 4.1. A etapa de classificação foi direcionada a duas estratégias, sendo elas: estação seca (ano de referência 2017) e métricas LSP (ciclo de crescimento 2017-2018). Ainda, foram testadas duas abordagens: uso conjunto (todos os IVs ou todas as métricas LSP derivadas dos IVs) e individual (apenas IVs e/ou métricas derivadas de IVs) das variáveis de entrada o RF. Os resultados foram comparados com o mapa de referência, formando a base para estimativa da acurácia da classificação e do mapa de incertezas gerado pela Entropia de Shannon. Os passos são detalhados abaixo.

Figura 4.1 - Diagrama metodológico com as etapas do processo de classificação RF de savanas para avaliar o uso de métricas fenológicas da vegetação *versus* índices de vegetação na estação seca.



Fonte: Produção da autora.

4.1 Seleção da área de estudo

Com mais de 30 anos de área preservada, a ESAE foi selecionada como área de estudo por conter fisionomias representativas do bioma Cerrado (MUNHOZ; RIBEIRO, 2008; FELFILI et al., 2007). Na perspectiva da análise fenológica por satélite, foi possível observar o comportamento sazonal de diferentes tipos de vegetação ao longo do tempo, o que potencializou a avaliação sobre a estratégia de classificação proposta. Baseada nas

classes de Ribeiro e Walter (1998), oito fitofisionomias foram consideradas na classificação: CL, CS, CC, CR, CT, CD, VE e MG. Alguns poucos locais em processo antigo de regeneração da vegetação, além de solo exposto e corpos d'água, foram desconsiderados da análise.

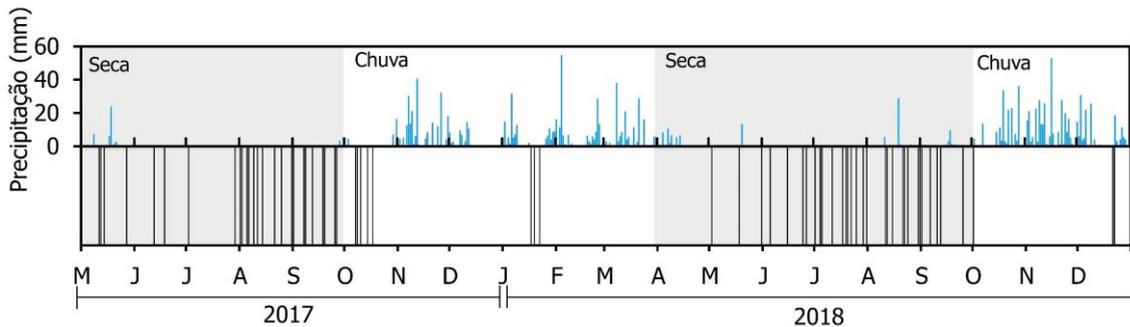
4.2 Aquisição dos dados PlanetScope e pré-processamento da série temporal

Nesse estudo foi utilizado o produto de reflectância da superfície ortoretificado nível-3B (*PlanetScope Ortho Scene Product*), que inclui correções geométrica, atmosférica e radiométrica (Planet Labs Inc, 2020; WANG et al., 2020). A etapa preliminar de preparação dos dados consistiu na avaliação visual das imagens e metadados, acerca da presença de nuvens e sombras de nuvens sobre a área. Foram mantidas apenas imagens livres desses artefatos.

Esse método foi empregado devido às limitações na utilização da máscara de qualidade *Unusable Data Mask* (UDM) da Planet, em tentativas de automatizar a detecção de pixels com presença de nuvens e sombras de nuvens (CHENG et al., 2020; WANG et al., 2020;). Diante da lacuna, mesmo com a adoção de métodos automáticos de detecção de nuvens e sombras, a avaliação visual dos dados foi necessária. Além disso, em função das mudanças nas especificações dos sensores desde os primeiros lançamentos da Planet, foram usados apenas satélites da primeira geração (PS2), cujo os sensores operam em quatro bandas espectrais: blue (464-517 nm); green (547-585 nm); red (650-682 nm); e NIR (846-888 nm).

Após inspeção visual e avaliação das imagens quanto a presença de nuvens e sombras e o sensor de origem (geração PS2), foram selecionadas 70 datas livres de cobertura de nuvens adquiridas de 1 de maio de 2017 a 31 de dezembro de 2018. Como pode ser visto na Figura 4.2, essa estratégia conservadora de filtragem dos dados e seleção de imagens criou lacunas na série temporal durante a estação chuvosa.

Figura 4.2 - Frequência de imagens livres de nuvens (linhas pretas na vertical na representação inferior) adquiridas pela PlanetScope (PS) sobre a área de estudo durante a estação de crescimento 2017-2018. A precipitação diária registrada no período de análise pela estação meteorológica automática A045 é mostrada na representação superior.



Fonte: Produção da autora.

Para preencher as falhas na série temporal e produzir uma série com frequência regularmente espaçada, o método de interpolação temporal *Locally Adjusted Cubic-spline* (LACC) foi aplicado nos dados (CHEN et al., 2006). O LACC gera um parâmetro de suavização local variável em um procedimento de interação concebido para produzir uma curva de nivelamento sazonal de substituição progressiva de valores anormais por valores ajustados. Em comparação com outros métodos, o LACC reduz o tempo computacional e as complexidades associadas aos polinômios de graus maiores (XUEYING et al., 2021). Além disso, o método *cubic-spline* é flexível para simular uma vasta gama de padrões de variação sazonal, bem como para reproduzir padrões de variação rápida ou lenta em diferentes estações (CHEN et al., 2006).

4.3 Determinação das métricas fenológicas

As métricas fenológicas foram determinadas a partir da série temporal de cada índice de vegetação NDVI (Equação 2.1), EVI (Equação 2.2) e GRND (Equação 2.3). O algoritmo *greenbrown*, um pacote disponível na linguagem de programação R (FORKEL et al, 2013; FORKEL; WUTZLER, 2015), foi utilizado para determinar um conjunto de 12 métricas fenológicas da vegetação em parâmetros de DOY e valores de IV. A partir da cronologia dos dados sazonais, uma estação de crescimento é determinada para cada ano e as métricas são obtidas.

As estimativas das métricas LSP foram feitas a partir do estabelecimento do início e fim da estação de crescimento (SOS e EOS, respectivamente). Ambas as métricas foram determinadas com base no limiar de 50% da fase ascendente e descendente das curvas

espectrais, respectivamente, resultante da derivada da curva sazonal (FORKEL et al., 2015). Esse método foi proposto por Tateishi e Ebata (2004) e é fundamentado na determinação de SOS quando a primeira derivada da curva ascendente atingiu o máximo local, ou seja, o aumento máximo do IV. Para EOS, observou-se quando a primeira derivada da curva descendente atingiu o mínimo local do IV (CAPARROS-SANTIAGO et al., 2021). Cheng e colaboradores (2020) utilizaram o mesmo limiar de 50% para determinar as métricas de SOS e EOS, empregando uma abordagem diferente, obtendo bons resultados.

Estabelecidas SOS e EOS, todas as outras métricas foram derivadas, sendo elas: comprimento da estação de crescimento (LOS em dias), que consiste na diferença entre EOS e SOS; dias em que ocorrem o valor máximo (POP em DOY) e o valor mínimo (POT em DOY) do IV; valores médios do IV na primavera/*green up* (MSP) ou no outono/senescência (MAU), e durante a estação de crescimento (MGS); valor máximo de IV na estação de crescimento (PEAK) e valor mínimo (TRG); taxa de *green up* na primavera (RSP) e senescência no outono (RAU). Maiores detalhes acerca destas métricas LSP no pacote empregado podem ser consultados na documentação do algoritmo e em Forkel et al. (2015).

4.4 Análise dos dados

4.4.1 Resposta sazonal das fitofisionomias do Cerrado

Na análise exploratória do comportamento sazonal, os perfis espectro-temporais do NDVI, EVI e GRND, para cada fitofisionomia na estação de crescimento de 2017-2018, foram avaliados. De forma complementar, os valores de precipitação acumulada, registrada na estação meteorológica automática A045, foram utilizados para avaliar as taxas de mudanças nos IVs com a ocorrência dos primeiros eventos de chuva registrados sobre as formações campestres e savânicas (abertas e densas).

O período de análise foi direcionado às primeiras chuvas após a estação seca do ano de 2017 (final do mês de setembro), período esse em que o estresse hídrico chegou a três meses (Figura 3.2). Em geral, 2017 apresentou alguns meses (p.ex., outubro e dezembro) com precipitação abaixo da média anual entre 2009-2020 (Figura 3.2). A avaliação sobre qual tipo de formação responde mais rapidamente a precipitação, após intensa estiagem,

e para qual volume acumulado de precipitação o maior incremento de IV acontece, foi baseada no cálculo da taxa de mudança dos IVs, apresentado na Equação 4.1.

$$\left| \frac{(IV_{t1} - IV_{t2}) \times 100}{IV_{t1}} \right| \quad (4.1)$$

Em que IV_{t2} refere-se ao valor de IV observado na data de referência e IV_{t1} é o valor de IV observado uma data antes; calculado em módulo, o resultado é expresso em porcentagem (%).

Para antecipar o potencial da fenologia da vegetação em discriminar fitofisionomias savânicas e inspecionar a presença de possíveis problemas no processamento dos dados no *greenbrown*, foram gerados 36 mapas das métricas LSP (12 mapas por IV). Os mapas das métricas LSP foram então comparados e avaliados em relação ao mapa de referência da vegetação da ESAE, produzido por Geologica Ecotech (2009) e adaptado de Jacon et al. (2017; 2021). A finalidade foi detectar possíveis inconsistências nos resultados.

4.4.2 Classificação Random Forest para a estação seca (IVs) versus fenologia da vegetação (métricas LSP)

Baseado em estudos prévios que testaram diversos classificadores sobre áreas de savanas brasileiras (TONIOL et al., 2017), a técnica de classificação não-paramétrica supervisionada Random Forest foi selecionada. A classificação foi realizada na linguagem de programação R com o auxílio do pacote *randomForest* (LIAW; WIENER, 2002). Os parâmetros *ntree* e *mtry* foram ajustados para 500 e para a raiz quadrada do número total de variáveis preditoras, respectivamente.

Como referência para atribuição das amostras, o mapa de vegetação de referência foi reprojetoado para a resolução espacial do produto PS (3,7 m). As fitofisionomias que sofreram alguns ajustes neste processo de compatibilização de escalas foram Veredas e Mata de Galeria, com formato linear alongado. Posterior a atualização do mapa de referência, 1000 amostras aleatórias estratificadas (*pixel* por classe) foram atribuídas, totalizando 8000 *pixels*. Para evitar autocorrelação, uma distância mínima de 11 metros (3 *pixels*) foi estabelecida para selecionar as amostras. O número total de 8000 *pixels* amostrados foi então dividido em amostras de treinamento (70%) e validação (30%) dos dados.

A classificação RF foi conduzida sobre duas estratégias, sendo elas: classificação RF derivada das métricas LSP (estação de crescimento de 2017-2018) e a classificação RF derivada de 12 imagens PS da estação seca, adquiridas entre 27 de julho e 1 de setembro de 2017 (datas próximas do pico da estação seca). O objetivo foi oferecer ao classificador o mesmo número de variáveis preditoras que as métricas LSP, assegurando uma comparação justa entre os resultados das classificações. Para avaliar a classificação das oito fitofisionomias a partir das métricas LSP, submetemos o classificador RF sobre cada conjunto isolado de 12 métricas fenológicas (SOS, EOS, LOS, POP, POT, MSP), MGS, MAU, TRG, PEAK, RSP e RAU) calculadas a partir de cada IV (NDVI, EVI e GRND). Essa etapa resultou em três mapas de classificação.

4.4.3 Classificação Random Forest para uso combinado *versus* conjunto isolado das variáveis

Baseado em um estudo recente feito por Souza et al. (2021), o qual indicou que a acurácia global da detecção de distúrbios sobre áreas de savana no Brasil aumentou com o uso combinado de IVs, dois cenários foram testados. Para o primeiro cenário, um total de 36 variáveis preditoras da estação seca (12 datas de imagens PS da estação seca de cada IV) foram submetidas a classificação RF. No segundo cenário, um total de 36 variáveis preditoras LSP (12 métricas LSP calculadas para cada um dos três IVs) foram usadas como dados de entrada para a classificação. Utilizando essas duas estratégias e comparando os resultados com os da seção anterior, foram avaliados os ganhos relativos de classificação RF resultantes da utilização das informações LSP para cada IV utilizado de forma combinada na classificação, em relação ao uso dos conjuntos isolados (variáveis derivadas dos IVs isoladamente).

4.5 Validação

O desempenho dos modelos RF de cada abordagem empregada foi avaliado com base na comparação visual entre a classificação obtida e o mapa de referência da vegetação da ESAE, elaborado pela Geologica Ecothech (2009) e adaptado por Jacon et al. (2017; 2021). A partir do conjunto de *pixels* de validação (30%), matrizes de confusão foram obtidas e as métricas relacionadas foram reportadas: *acurácia total* da classificação (OA); *Precision* (P); *Recall* (R); e *F1-score* (F). De forma complementar, a incerteza da

classificação também foi avaliada através do cálculo da entropia de Shannon, como será detalhado adiante.

As métricas de precisão foram usadas como critério para determinar a melhor abordagem para classificar as fitofisionomias (informação da estação seca *versus* métricas LSP; uso combinado de métricas *versus* uso individual). OA (Equação 4.2) representa a porcentagem total de pixels corretamente classificados; P (Equação 4.3) é a probabilidade de um pixel atribuído a uma classe ser realmente da classe (erros de comissão); R (Equação 4.4) compreende a probabilidade de um pixel de determinada classe ser classificado corretamente (erros de omissão); e F (Equação 4.5) configura a média harmônica entre P e R, ou seja, a razão entre os erros de comissão e omissão. Basicamente, essas métricas representam a capacidade da classificação em prever corretamente as classes.

$$OA = \frac{VP + VN}{VP + FP + VN + FN} \quad (4.2)$$

$$R = \frac{VP}{VP + FN} \quad (4.3)$$

$$P = \frac{VP}{VP + FP} \quad (4.4)$$

$$F1 \text{ score} = 2 \times \frac{P \times R}{P + R} \quad (4.5)$$

onde *VP* é verdadeiro positivo (concordância entre a classe predita e classe de referência); *VN* é verdadeiro negativo (concordância entre não ser determinada classe predita e de fato não ser a classe de referência); *FP* é falso positivo (incoerência entre a classe predita e a classe de referência); e *FN* é falso negativo (incoerência entre não ser determinada classe predita e ser a classe de referência).

Para garantir a confiança na precisão da classificação, a entropia de Shannon (GRAY, 2011) foi calculada. Esse método permite quantificar as incertezas no processo de decisão da classificação (GONÇALVES et al., 2009; TONIOL et al., 2017). De forma geral, a entropia analisa a classificação de maneira probabilística, ou seja, considerando um conjunto de probabilidade de ocorrência dos eventos possíveis (classes). Como o Random

Forest é um classificador baseado em árvores de decisão, a entropia irá avaliar a distribuição probabilística da atribuição dos votos nas diferentes classes. Assim, o valor de entropia máxima é atingido quando a proporção de votos entre as classes é igual (probabilidade equiprovável), enquanto a menor entropia será associada à concentração de probabilidade, ou seja, os votos foram atribuídos com baixa variabilidade entre as árvores e em maior proporção em determinada classe. A medida de entropia pode revelar ainda a dificuldade do classificador em atribuir os votos em classes específicas, com base nos atributos fornecidos, por exemplo. A Equação 4.6 apresenta o cálculo da entropia de Shannon (E) a partir de uma função, cujos valores variam no intervalo de 0 a $\log_2 n$, sendo n o número de classes.

$$E = - \sum_{i=1}^n p_i \log_2 p_i \quad (4.6)$$

Em que p é a probabilidade de ocorrência de cada evento i (neste caso i corresponde a classe) em relação a todas as ocorrências possíveis de serem obtidas a partir da proporção de votos em todas as árvores de decisão do classificador RF.

Finalmente, durante a classificação RF, a performance das variáveis preditoras foi elencada usando a *Mean Decrease in Accuracy* (MDA). Essa métrica representa a contribuição das variáveis para a acurácia de cada classificação RF (BREIMAN, 2001). Para esse propósito, o pacote *rfPermute* v2.1.6 (ARCHER, 2018) disponível no R foi utilizado. A fim de identificar quais variáveis mostraram MDAs significativamente diferentes da distribuição nula ao nível de significância de 5%, o modelo foi executado 30 vezes enquanto as mostras eram embaralhadas de forma aleatória (DALAGNOL et al., 2019).

5 RESULTADOS

5.1 Resposta sazonal dos índices de vegetação nas savanas

O comportamento sazonal dos IVs, derivados das imagens PS na estação de crescimento 2017-2018, mostrou variações significativas da estação chuvosa (outubro-abril) para a seca (maio-setembro) (Figura 5.1). Para todo o ciclo sazonal, menores valores de IV foram geralmente observados em áreas de savanas campestres. Para NDVI e EVI, os valores mínimos foram observados para a fitofisionomia Campo Limpo, em torno de 0,25 e 0,20, respectivamente, na estação seca prévia ao início da estação de crescimento. Nos perfis do GRND, os menores valores ocorreram em áreas de Cerrado Ralo. Na estação seca seguinte (a partir de junho de 2018), valores maiores de IV ocorreram em função da disponibilidade de chuvas no período. Em média, a amplitude sazonal dos IVs (estação chuvosa menos estação seca) apresentou uma diferença da ordem de 0,25 (SG, OWS e DWS), no NDVI e EVI, e de 0,10 no GRND.

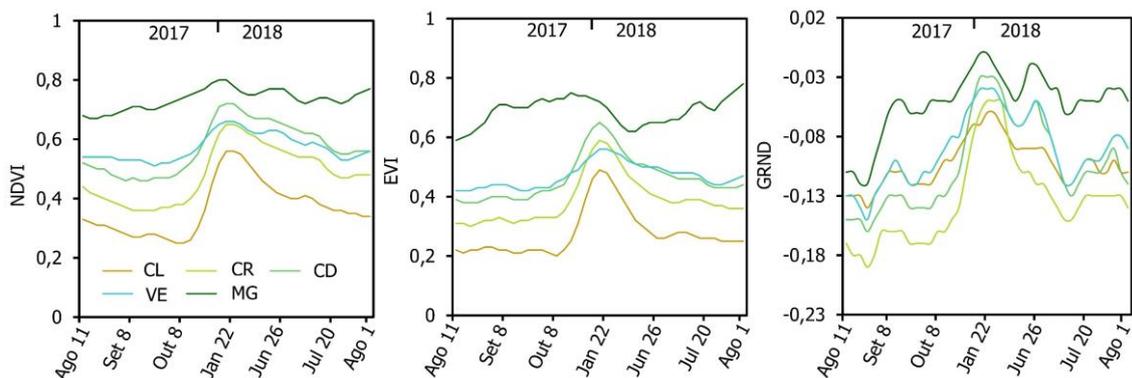
Para a maioria das fitofisionomias, os valores máximos de IV foram observados no mês de janeiro, que coincide com o pico da estação chuvosa. Os valores mínimos de IV foram registrados entre agosto e setembro, período em que ocorre o máximo déficit hídrico. Novamente o comportamento das fitofisionomias é similar entre os índices NDVI e EVI, com pico na estação chuvosa, registrado em meados do mês de janeiro, e com valores crescentes entre as fitofisionomias (CL, CR, CD, VR e MG). EVI e GRND apresentaram a mesma sequência de valores máximos associados às fitofisionomias, sendo que VE apresentou um valor ligeiramente menor do que CD para os dois índices.

Da estação chuvosa para a seca, foi observada uma forte redução sazonal nos valores de NDVI (Figura 5.1a), EVI (Figura 5.1b) e GRND (Figura 5.1c) associada às coberturas vegetais dos tipos savanas densas (CD) e campestres (CL). Devido a ocorrência ao longo de corpos d'água e, conseqüentemente, menor sensibilidade ao déficit hídrico, GF e VE mostraram variações sazonais nos IVs comparativamente menores do que as observadas para outras fitofisionomias, especialmente para NDVI e EVI. Espécies sempre-verdes são predominantes em áreas de GF. Por outro lado, grandes quantidades de espécies decíduas são observadas em formações savânicas.

Quando comparados com o NDVI (Figura 5.1a) e EVI (Figura 5.1b), os perfis ruidosos do GRND (Figura 5.1c) são explicados pela proximidade das bandas do verde e do

vermelho na constelação de satélites PS (funções de resposta dos detectores), utilizadas no cálculo do GRND, e pela possível influência residual de efeitos de espalhamento atmosférico no intervalo do visível.

Figura 5.1 - Variações sazonais no (a) NDVI, (b) EVI e (c) GRND durante a estação de crescimento 2017-2018 para cinco das oito fitofisionomias de Cerrado com adensamento da cobertura vegetal de CL para MG.



Abreviações: CL (Campo Limpo), CR (Cerrado Ralo), CD (Cerrado Denso), VE (Veredas) e MG (Mata de Galeria).

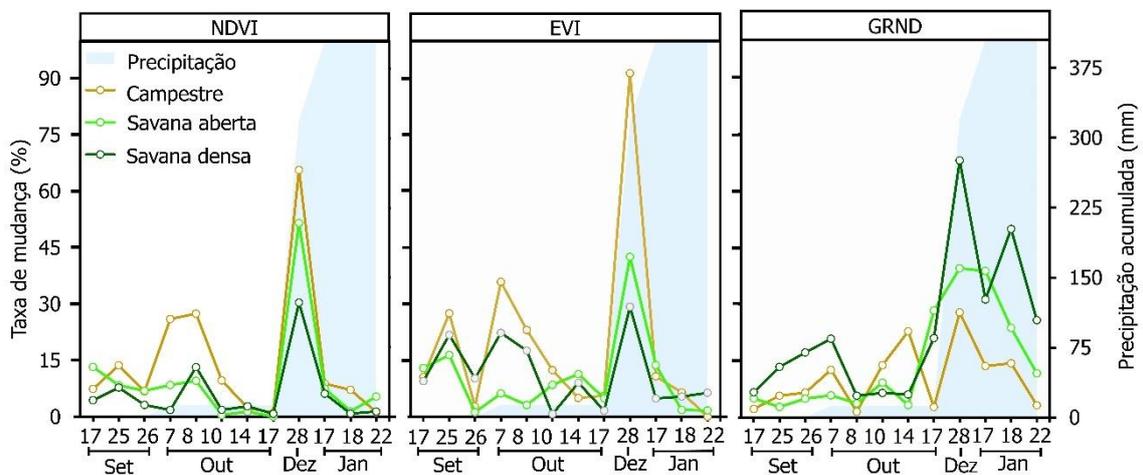
Fonte: Produção da autora.

As fitofisionomias de Cerrado possuem diferentes intensidades de resposta dos IVs para a precipitação, o que torna as métricas fenológicas potencialmente úteis para fins de classificação. Por exemplo, quando foi fixada a data de final da estação seca de 2017 em 19 de setembro, após um período de três meses sem nenhum registro de precipitação, foram observadas diferentes taxas de mudança nos IVs relacionadas aos primeiros eventos de precipitação da estação chuvosa (Figura 5.2). Nas datas de 19, 25 e 26 de setembro, ainda na estação seca e com pluviosidade zero, a variação dos IVs foi menor que 15% e 20% no NDVI e GRND, respectivamente, e 30% no EVI. A magnitude entre os valores de IVs das fitofisionomias também permaneceu baixa.

A partir da imagem PS adquirida em de 7 de outubro, os primeiros registros de precipitação acumulada foram computados, onde a pluviosidade alcançou 13 mm, mas sem produzir nenhuma mudança significativa nos IVs. A maior taxa de mudança foi verificada entre 17 de outubro e 28 de dezembro, quando a precipitação acumulada apresentou aumento significativo de 13 para 300 mm. Para o NDVI e EVI, as taxas aumentaram de savanas densas para áreas campestres, mas um comportamento inverso foi observado para GRND (Figura 5.2). Dentre os três IVs, a maior taxa de variação

(91,4%) foi observada para EVI em áreas de Campo Limpo (CL), em 28 de dezembro de 2017, seguido de Cerrado Ralo (42,5%) e Cerrado Denso (29,2%). Para GRND, o tipo de vegetação que apresentou maior taxa de mudança foi CD (68,1%), seguido por CR (68,1%) e CL (39,5%). Após 17 de janeiro a taxa de mudança diminuiu, como esperado, e a variação permaneceu estável para o NDVI e o EVI. Em GRND, ainda foi possível observar variações da magnitude de mudança após esta data, principalmente na fitofisionomia CD.

Figura 5.2 - Mudança média no NDVI, EVI e GRND com a ocorrência dos primeiros eventos de chuva no final de setembro de 2017. Os resultados referem-se a áreas representativas das fitofisionomias de Cerrado com incremento da cobertura vegetal.

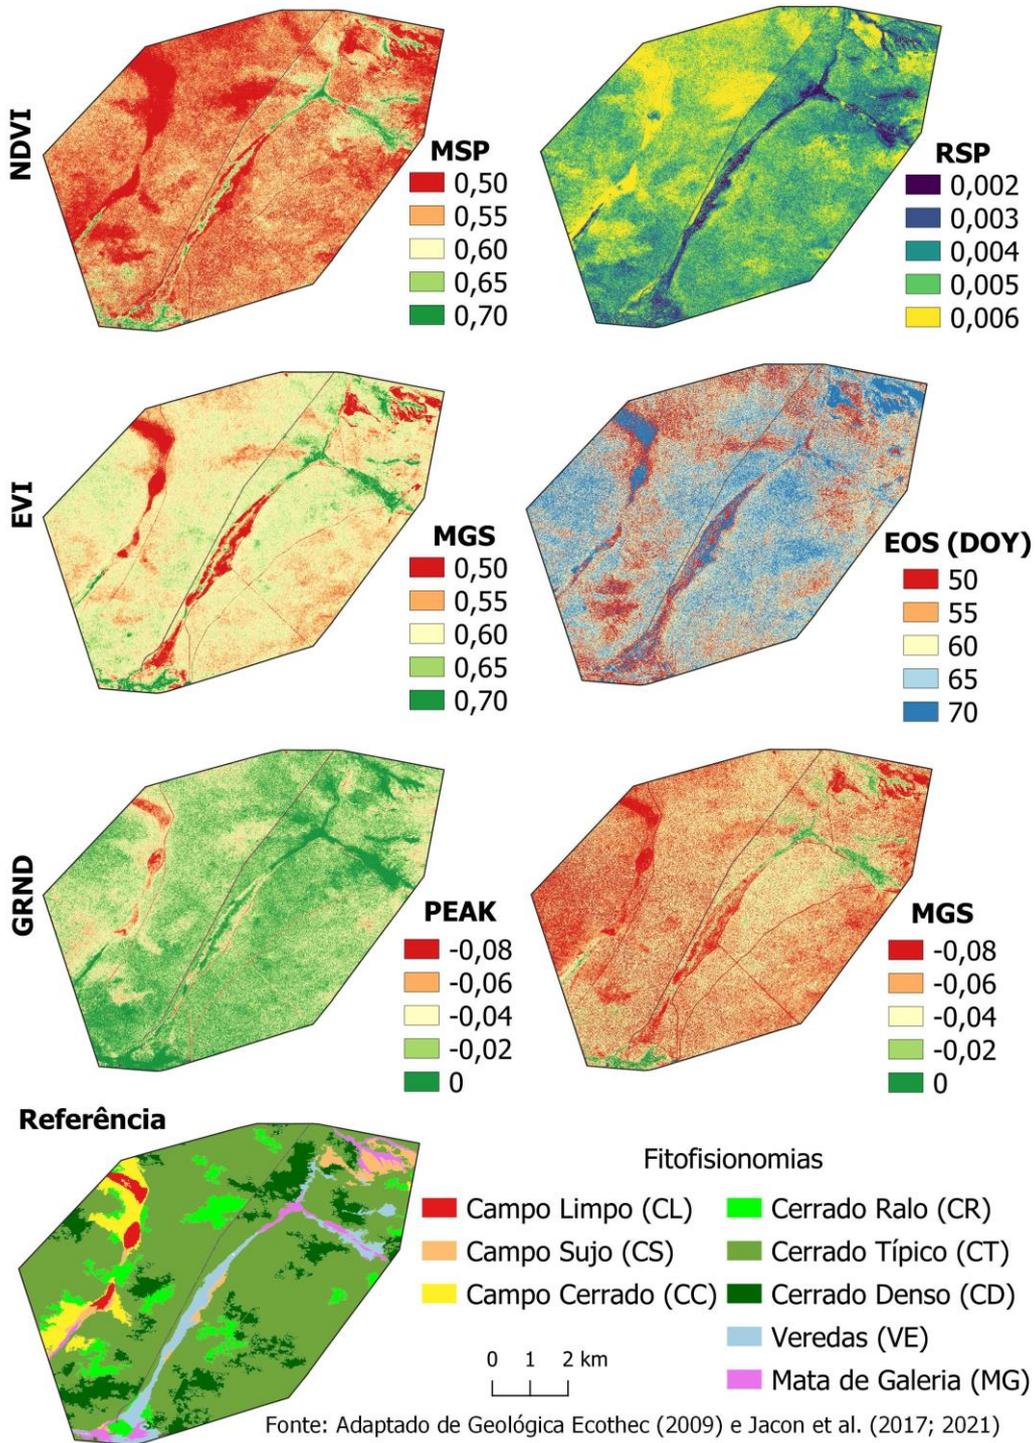


Fonte: Produção da autora.

5.2 Variações espaciais nas métricas fenológicas

Em razão das diferenças sazonais na resposta dos IVs à precipitação, ilustradas nas figuras 5.1 e 5.2, a distribuição espacial de algumas métricas LSP, calculadas pelo algoritmo *greenbrown*, manteve uma estreita semelhança com a ocorrência espacial de algumas fitofisionomias. Por exemplo, ao comparar o mapa de referência da vegetação com os mapas LSP da constelação de satélites PS, métricas como MSP, RSP, MGS, EOS e PEAK, calculadas a partir dos três IVs, separaram bem formações campestres (CL e CS) das demais fitofisionomias remanescentes (Figura 5.3). Áreas de formações campestres apresentaram os mais baixos valores de MGS do EVI (0,50) e GRND (-0,08), possuindo um EOS tardio de EVI (DOY 70), quando comparado com as métricas de outras formações.

Figura 5.3 - Variação espacial de algumas métricas fenológicas, derivadas dos diferentes índices de vegetação (NDVI, EVI e GRND) pelo algoritmo *greenbrown*, quando comparado ao mapa de referência da vegetação da ESAE.



Abreviações: MSP (IV médio na primavera); RSP (taxa de *green up* na primavera); MGS (valor médio de IV na estação de crescimento); EOS (dia em que ocorre o final da estação); PEAK (máximo valor de índice de vegetação).

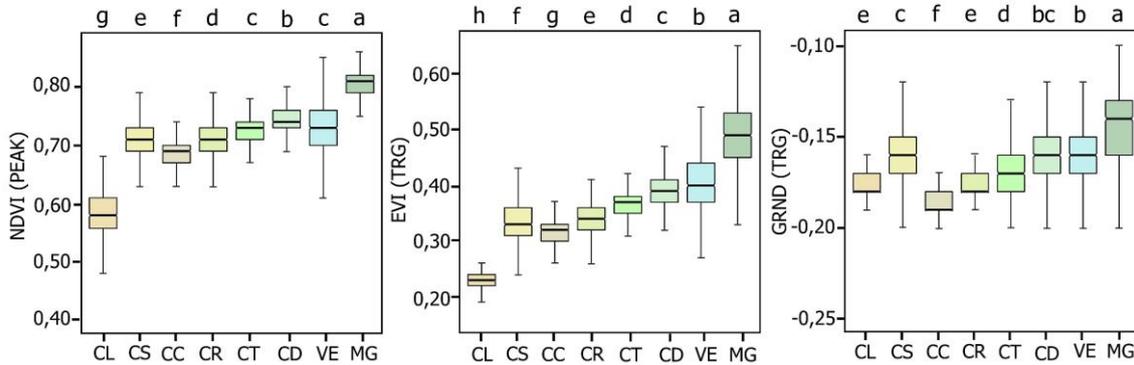
Fonte: Produção da autora.

Como observado no mapa de referência da vegetação na Figura 5.3, áreas de CR e CD corresponderam a: valores baixos de MSP do NDVI (0,50); valores altos de RSP do NDVI (0,006); e um EOS mais precoce em EVI (DOY 50). MG foi bem delimitada pela maioria das métricas LSP, mostrando altos valores de MSP em NDVI (0,70), baixo RSP em NDVI (0,002), alto valor de MGS em EVI (0,70) e PEAK de GRND próximo de zero. No entanto, outras fitofisionomias importantes da ESAE mostraram algum grau de confusão em discriminá-las a partir das métricas LSP.

Campo Cerrado, por exemplo, apresentou associação à baixos valores de MSP (0,50) e alto RSP (0,006) em NDVI, assim como valores intermediários de PEAK (-0,04) em GRND. Nessa condição, CC apresentou confusões visuais com CS e CR. Esse também foi o caso de CT, que é o tipo de vegetação mais predominante na área de estudo, ocupando cerca de 60% da ESAE (cor verde predominante no mapa de referência da Figura 5.3). Em áreas de CT no mapa, ocorrem manchas de CR e CD com alta variabilidade de métricas LSP. VE foi uma fitofisionomia bem definida por quase todas as métricas, mas apresentou variações na abrangência de seu limite. Em MGS (EVI), por exemplo, valores médios (0,60) e baixos (0,50) foram observados em VE; para a métrica PEAK (GRND), valores próximos a zero e médios (-0,04) ocorreram sobre a área; em MSP (NDVI), valores baixos (0,50), médios (0,60) e altos (0,70) foram observados na mesma região.

De forma complementar, a análise de variância (ANOVA), seguida do teste de Tukey-Kramer, mostrou que algumas métricas LSP apresentaram diferenças significativas entre pares de fitofisionomias, enquanto outras foram estatisticamente iguais (5% significância). Por exemplo, métricas como PEAK (NDVI) e TRG (EVI e GRND) tiveram desempenho variável para discriminar as savanas. Como pode ser observado na Figura 5.4a, o PEAK do NDVI separou cinco das oito fitofisionomias ao nível de 5% de significância. Por outro lado, TRG do EVI mostrou diferenças estatísticas significativas entre todas as fitofisionomias (Figura 5.4b). Finalmente, confusões entre CL e CR foram observadas no teste conduzido para TRG do GRND, assim como entre CS, CD e VE (Figura 5.4c).

Figura 5.4 - Variações nos valores máximos (PEAK) e mínimos (TRG) de (a) NDVI, (b) EVI e (c) GRND para as oito fitofisionomias em estudo. As letras indicam diferenças estatísticas entre as métricas fenológicas ao nível de 5% de significância (Tukey-Kramer teste).



Abreviações: CL (Campo Limpo); CS (Campo Sujo); CC (Campo Cerrado); CR (Cerrado Ralo); CT (Cerrado Típico); CD (Cerrado Denso); VE (Veredas); MG (Mata de Galeria).

Fonte: Produção da autora.

5.3 Classificação IVs da estação seca versus LSP

Na classificação RF usando IVs de 12 imagens PS adquiridas na estação seca, o maior OA alcançado foi para o NDVI (0,61), seguido do EVI (0,57) e GRND (0,56) (Tabela 5.1). Os resultados das classificações RF para o uso não combinado das variáveis, com respeito à discriminação das fitofisionomias e ao número de pixels utilizados para validação, podem ser consultados no Apêndice A.2.

Os valores obtidos de *Precision* foram normalmente superiores a 0,50 para o NDVI para a maioria das fitofisionomias (Tabela 5.1), exceto para CS (0,43), CR (0,34) e CT (0,46). Esses valores de P podem expressar baixa taxa de falsos positivos. No entanto, os índices EVI e GRND apresentaram valores inferiores aos do NDVI, indicando maiores erros de comissão para estes dois IVs. Para ambos IVs, CL, CC e MG foram as fisionomias com maiores valores de *Precision*.

Por outro lado, os valores mais baixos de *Recall* no NDVI foram associados as fitofisionomias CR (0,41), CT (0,46) e CD (0,49) e os erros de omissão para EVI foram reportados para CT (0,37), CD (0,40), CR (0,40) e CS (0,49). CT (0,41), CR e CD (0,45) tiveram baixos valores de *Recall* para GRND (Tabela 5.1). Esses valores indicam a presença de falsos negativos no processo de classificação das fitofisionomias durante a estação seca. No entanto, quando levamos em consideração os falsos positivos e falsos

negativos, os valores de *F1-score* médio foram maiores que 0,50 (Tabela 5.1), com desvio padrão de 0,14 (GRND), 0,19 (NDVI) e 0,22 (EVI).

Quando comparada à classificação na estação seca usando apenas IVs, o uso separado das 12 métricas LSP derivadas de cada IV elevaram a OA de 0,61 para 0,69 no NDVI; de 0,57 para 0,68 no EVI; e de 0,56 para 0,58 no GRND. Esses resultados representaram ganhos de OA em 19,3%, 13,1% e 3,6% para o EVI, NDVI e GRND, respectivamente. Como pode ser observado na Figura 5.5, o efeito da inclusão da informação fenológica na classificação RF produziu um aumento na acurácia dos valores de *Precision*, *Recall* e *F1-score* para a maioria das fitofisionomias, especialmente para métricas fenológicas derivadas do NDVI.

Tabela 5.1 - Matriz de erro da classificação Random Forest de oito fitofisionomias de Cerrado usando 12 imagens PlanetScope da estação seca de 2017 e métricas LSP dos índices de vegetação (NDVI, EVI e GRND).

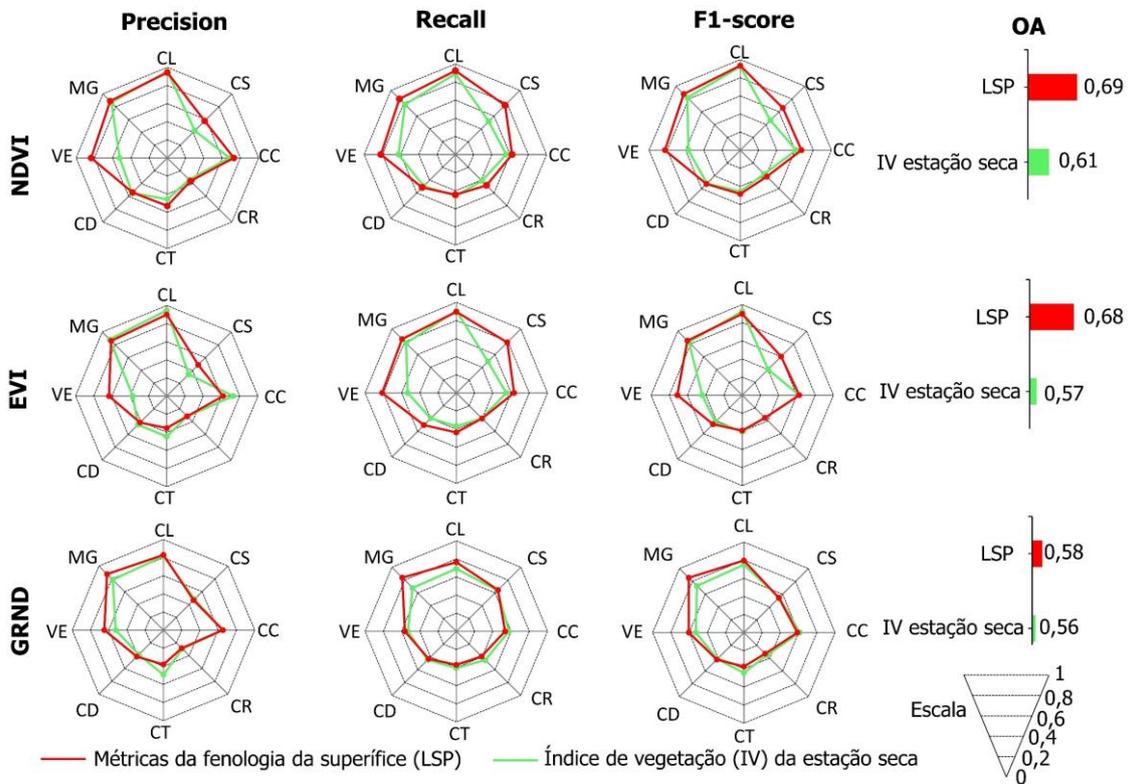
<i>Variáveis não combinadas</i>																		
Fitofisionomias	Estação seca									Métricas LSP								
	NDVI			EVI			GRND			NDVI			EVI			GRND		
	P	R	F	P	R	F	P	R	F	P	R	F	P	R	F	P	R	F
CL	0.96	0.89	0.92	0.95	0.91	0.93	0.82	0.69	0.75	0.94	0.92	0.93	0.90	0.90	0.90	0.83	0.76	0.80
CS	0.43	0.52	0.47	0.34	0.49	0.40	0.48	0.64	0.55	0.58	0.77	0.66	0.49	0.79	0.60	0.47	0.65	0.54
CC	0.68	0.56	0.61	0.73	0.55	0.62	0.65	0.58	0.61	0.73	0.62	0.67	0.62	0.63	0.62	0.65	0.53	0.59
CR	0.34	0.41	0.37	0.32	0.40	0.35	0.29	0.45	0.35	0.36	0.48	0.41	0.32	0.40	0.35	0.28	0.39	0.33
CT	0.46	0.46	0.46	0.45	0.37	0.40	0.49	0.41	0.45	0.53	0.44	0.48	0.35	0.44	0.39	0.38	0.37	0.38
CD	0.55	0.49	0.52	0.45	0.40	0.42	0.38	0.45	0.41	0.54	0.51	0.53	0.41	0.50	0.45	0.41	0.43	0.42
VE	0.52	0.62	0.57	0.37	0.53	0.44	0.52	0.53	0.53	0.84	0.82	0.83	0.63	0.81	0.71	0.65	0.56	0.60
MG	0.87	0.78	0.82	0.88	0.78	0.83	0.79	0.68	0.73	0.89	0.87	0.88	0.86	0.84	0.85	0.87	0.84	0.86
F-médio (std)	0.59 (0.19)			0.55 (0.22)			0.55 (0.14)			0.67 (0.19)			0.61 (0.20)			0.56 (0.19)		
OA	0.61			0.57			0.56			0.69			0.68			0.58		

Abreviações: CL (Campo Limpo); CS (Campo Sujo); CC (Campo Cerrado); CR (Cerrado Ralo); CT (Cerrado Típico); CD (Cerrado Denso); VE (Veredas); MG (Mata de Galeria); LSP (*Land Surface Phenology*); P (*Precision*); R (*Recall*); F (*F1-score*); std (*desvio padrão*); OA (*overall accuracy*).

Fonte: Produção da autora.

A taxa de falsos positivos diminuiu para a maioria das fisionomias quando foi empregada a classificação RF usando métricas LSP derivadas do NDVI, como pode ser observado pelo aumento da *Precision*. Exceto para CL e CD, com redução de 0,02 e 0,01, respectivamente, as demais classes apresentaram ganhos de até 0,31, como é o caso de VE. No EVI, esse comportamento foi observado apenas para as fitofisionomias CS e VE, com aumento de 0,06 e 0,11, respectivamente. No GRND, houve aumento de P para CL (0,01), CD (0,03), VE (0,13) e MG (0,09).

Figura 5.5 - Diferenças na *Precision*, *Recall* e *F1-score* entre as abordagens de classificação Random Forest da estação seca de 2017, com índices de vegetação, e do ciclo sazonal de 2017-2018 com métricas fenológicas (LSP).



Abreviações: CL (Campo Limpo); CS (Campo Sujo); CC (Campo Cerrado); CR (Cerrado Ralo); CT (Cerrado Típico); CD (Cerrado Denso); VE (Veredas); MG (Mata de Galeria); LSP (*Land Surface Phenology*); OA (overall accuracy).

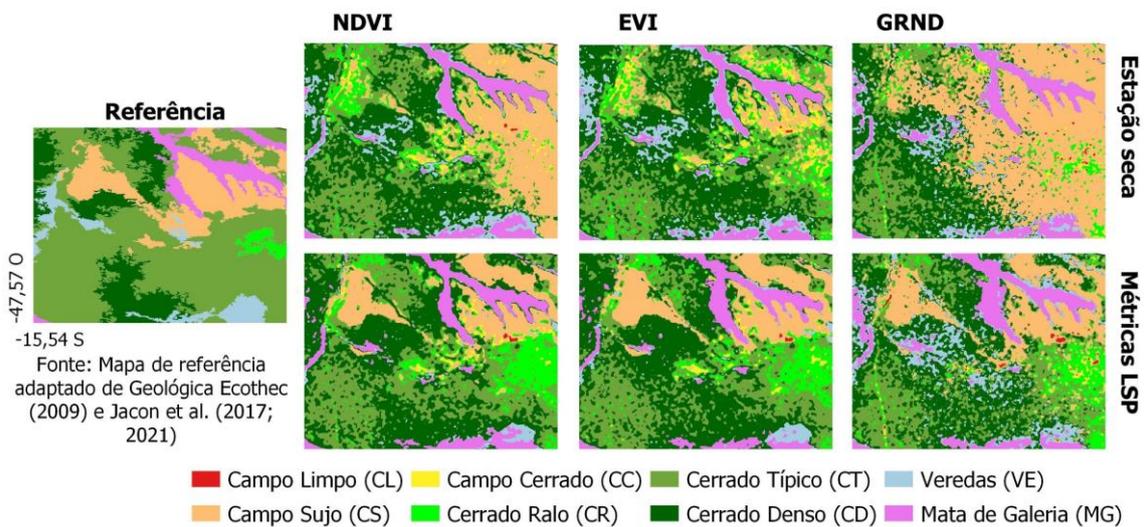
Fonte: Produção da autora.

Os falsos negativos também foram reduzidos na classificação a partir das métricas LSP do PlanetScope, como pode ser visto na Tabela 5.1 e na Figura 5.5, através do aumento nos valores de *Recall*. A única classe de vegetação que não apresentou aumento de *Recall* foi CT no NDVI e CL no EVI, ambas com 0,02 a menos de diferença para o *Recall* da estação seca. Os resultados de *Recall* para CR e EVI se mantiveram iguais, havendo

diminuição em 0,04; 0,06; 0,04; e 0,02 para GRND e CC, CR, CT e CD, respectivamente. A ponderação dos falsos positivos e falsos negativos, representada pela métrica *F1-score* médio, novamente demonstrou ganhos na classificação RF usando métricas LSP derivadas de IVs individuais, em relação à classificação RF utilizando IVs somente na estação seca. Os ganhos foram: 0,08 no NDVI que manteve o desvio padrão; de 0,06 no EVI com 0,02 de desvio padrão; e de 0,01 para GRND com aumento do desvio padrão em 0,05 e variação pouco expressiva do *F1-score* médio em 0,01.

A classificação final utilizando os IVs individualmente (datas da estação seca e métricas fenológicas) é apresentada no Apêndice A.1. Com base no mapa de referência foi possível observar a melhor discriminação das fitofisionomias realizada pela classificação RF, cujas variáveis predictoras foram as métricas LSP. Em sua maioria, as formações campestres (CL, CS e CC) (Figura 5.6) foram bem classificadas pelas métricas derivadas dos IVs NDVI e EVI, enquanto a classificação para métricas do GRND apresentou maior dificuldade em diferenciar as oito fitofisionomias. Com base nas imagens PS da estação seca, a classificação a partir do NDVI e EVI apresentou bons resultados na separação das classes CL, CC e MG, havendo confusão para diferenciar as outras fitofisionomias.

Figura 5.6 - Classificação Random Forest com o uso individual dos IVs da estação seca e das métricas fenológicas LSP para uma porção da ESAE onde ocorre concentração de seis fitofisionomias distintas.



Fonte: Produção da autora.

As confusões entre fitofisionomias foram observadas para as duas classificações conforme o aumento da cobertura vegetal. Esse padrão foi verificado para o NDVI e EVI

da estação seca e com a classificação a partir das métricas LSP do NDVI. Assim, fisionomias campestres se confundiram entre si, principalmente CL com CC, e, em menor proporção, CL com CS. Entre as formações savânicas e florestais, CR apresentou maior confusão associada a CC; CT com CD; e VE com MG. Nas classificações resultantes do uso isolado das variáveis extraídas do GRND (12 imagens PS da estação seca e 12 métricas LSP), houve variações entre as confusões. Nas fitofisionomias campestres, as confusões ocorreram, em sua maioria, entre CS e CT; e CC e CL. As demais fisionomias apresentaram confusões entre transições no gradiente vegetativo (Apêndice B).

5.4 Classificação para a abordagem conjunta de IVs e métricas LSP

O uso combinado dos IVs para a classificação RF a partir de 36 imagens PS (12 datas por IV) obtidas na estação seca de 2017, produziu ganhos significantes na OA, quando comparada à análise do uso isolado dos IVs. Por exemplo, mantendo o EVI da estação seca como referência de comparação, o OA foi de 0,57 (Tabela 5.1) para 0,70 (Tabela 5.2). Isso expressa um ganho de 22,8% no resultado de OA que resultou em melhorias significativas nos valores de *F1-score* observados em CS (aumento de 31%, Tabela 5.2), CR (15%) e VE (28%). Valores de R menores que 0,50 não foram observados (Tabela 5.2).

Ao comparar os melhores resultados da classificação da estação seca com imagens PS de NDVI (Tabela 5.1), o uso combinado dos três IVs da estação seca apresentou aumento na *Precision* de 0,01 (MG) a 0,23 (CS). Esses valores revelam que a classificação reduziu a taxa de falsos positivos, conseqüentemente, a P aumentou. A detecção de falsos negativos também foi minimizada com o aumento do *Recall*. Junto a isso, o F1-score também aumentou e os ganhos das três métricas (P, R e F) foram relacionados, principalmente, a classificação das fitofisionomias CS, CR, CT e VE. Esses resultados corroboram com a representação visual apresentada no Apêndice A.1, onde os IVs utilizados de forma isolada na classificação RF não foram capazes de discriminar áreas de CS na porção sul da ESAE, onde ocorrem manchas de CR em áreas de CT com confusões evidentes entre VE e MG.

Tabela 5.2 - Matriz de erro da classificação Random Forest de oito fitofisionomias de Cerrado, usando a abordagem conjunta de 36 índices de vegetação da estação seca (12 datas de NDVI, EVI e GRND) e 36 métricas da fenologia da superfície (LSP) (12 variáveis preditoras por IV: NDVI, EVI e GRND).

Fitofisionomias	Uso combinado das variáveis					
	Estação seca			Métricas LSP		
	P	R	F	P	R	F
CL	0.95	0.93	0.94	0.94	0.93	0.94
CS	0.66	0.77	0.71	0.61	0.86	0.71
CC	0.78	0.69	0.74	0.80	0.68	0.74
CR	0.45	0.56	0.50	0.41	0.51	0.45
CT	0.53	0.51	0.52	0.53	0.48	0.50
CD	0.58	0.52	0.55	0.63	0.58	0.60
VE	0.70	0.75	0.72	0.89	0.86	0.87
MG	0.88	0.80	0.84	0.91	0.87	0.89
F-médio (std)	0.69 (0.16)			0.71 (0.18)		
OA	0.70			0.73		

Abreviações: CL (Campo Limpo); CS (Campo Sujo); CC (Campo Cerrado); CR (Cerrado Ralo); CT (Cerrado Típico); CD (Cerrado Denso); VE (Veredas); MG (Mata de Galeria); LSP (*Land Surface Phenology*); P (*Precision*); R (*Recall*); F (*F1-score*); std (*desvio padrão*); OA (*overall accuracy*).

Fonte: Produção da autora.

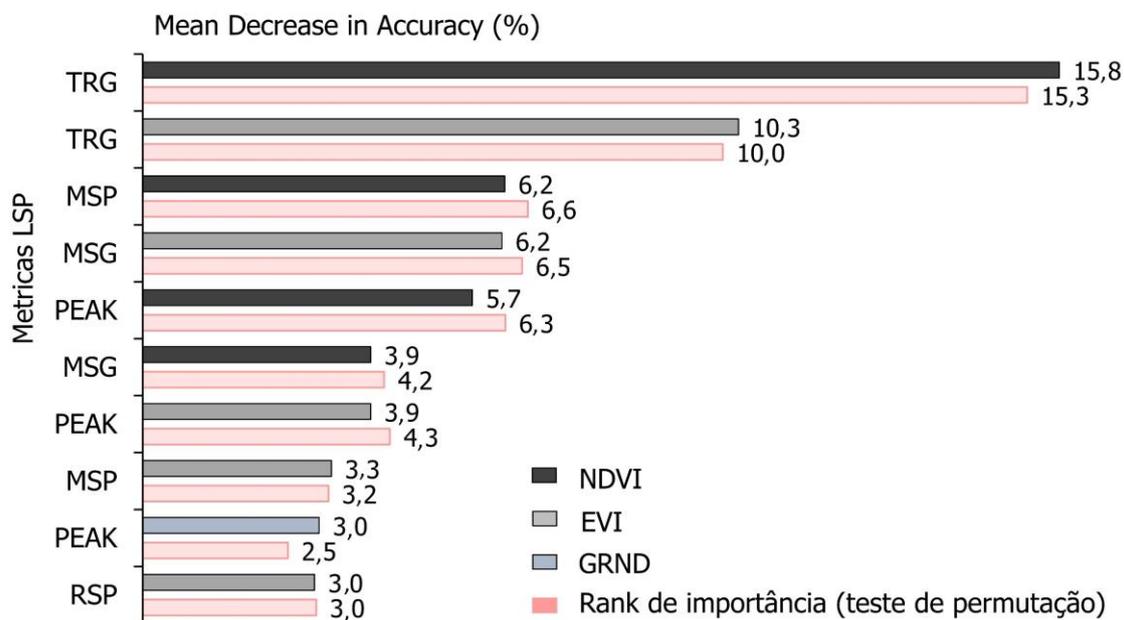
Os ganhos em OA foram ainda maiores quando a matriz de confusão do EVI na estação seca (Tabela 5.1) é comparada a matriz de erros da abordagem conjunta utilizando todas as 36 métricas LSP derivadas dos três IVs (NDVI, EVI e GRND) (Tabela 5.2). O aumento na OA foi de 0,57 para 0,73, produzindo um ganho de 28,1%. O *F1-score* médio calculado de todas as fitofisionomias variou de 0,67 (abordagem de classificação estação seca EVI) para 0,81 (abordagem de classificação LSP). Para a abordagem conjunta LSP, o maior *F1-score* foi observado sobre área de CL (0,96 na tabela 2), enquanto o menor valor foi reportado sobre áreas de CR (0,57 na Tabela 5.2).

Comparando os resultados da Tabela 5.2 de ambas as abordagens conjuntas (36 variáveis da estação seca versus métricas LSP), não foram observadas diferenças significativas entre as métricas de acurácia das duas matrizes de erros. Por exemplo, a OA variou de 0,70 (abordagem conjunto de IVs na estação seca de 2017) para 0,73 (abordagem conjunta de métricas LSP na estação de crescimento 2017-2018). Esses resultados sugerem que a

abordagem conjunta de IVs na estação seca é uma alternativa para eventual inacessibilidade de séries temporais densas de dados de satélite para a classificação de savanas. Na ausência de séries temporais densas para derivar métricas fenológicas da vegetação, o uso combinado de diferentes IVs calculados na estação seca, quando a cobertura de nuvens é reduzida, irá elevar a acurácia da classificação quando comparada a classificação utilizando IVs individualmente.

Na classificação Random Forest na abordagem conjunta das métricas LSP, o ranking de importância média para acurácia do modelo apontou que as 10 primeiras métricas elencadas foram associadas com o NDVI (TRG, MSP, PEAK e MGS), EVI (TRG, MGS, PEAK, MSP e RSP) e GRND (PEAK). Depois de usar 30 permutações e um nível de significância de 5%, essas métricas apresentaram os maiores valores de *Mean Decrease in Accuracy* (MDA) (Figura 5.7). As duas primeiras métricas mais importantes foram TRG do NDVI e EVI. Esses resultados foram consistentes com a diferença estatística observada entre todos os pares de fitofisionomias no teste Tukey-Kramer (Figura 5.4).

Figura 5.7 - Métricas LSP mais importantes para o modelo de classificação da abordagem conjunta usando 36 variáveis predictoras, expressas por valores de *Mean Decrease in Accuracy* calculada de 30 permutações ao nível de significância de 5%.

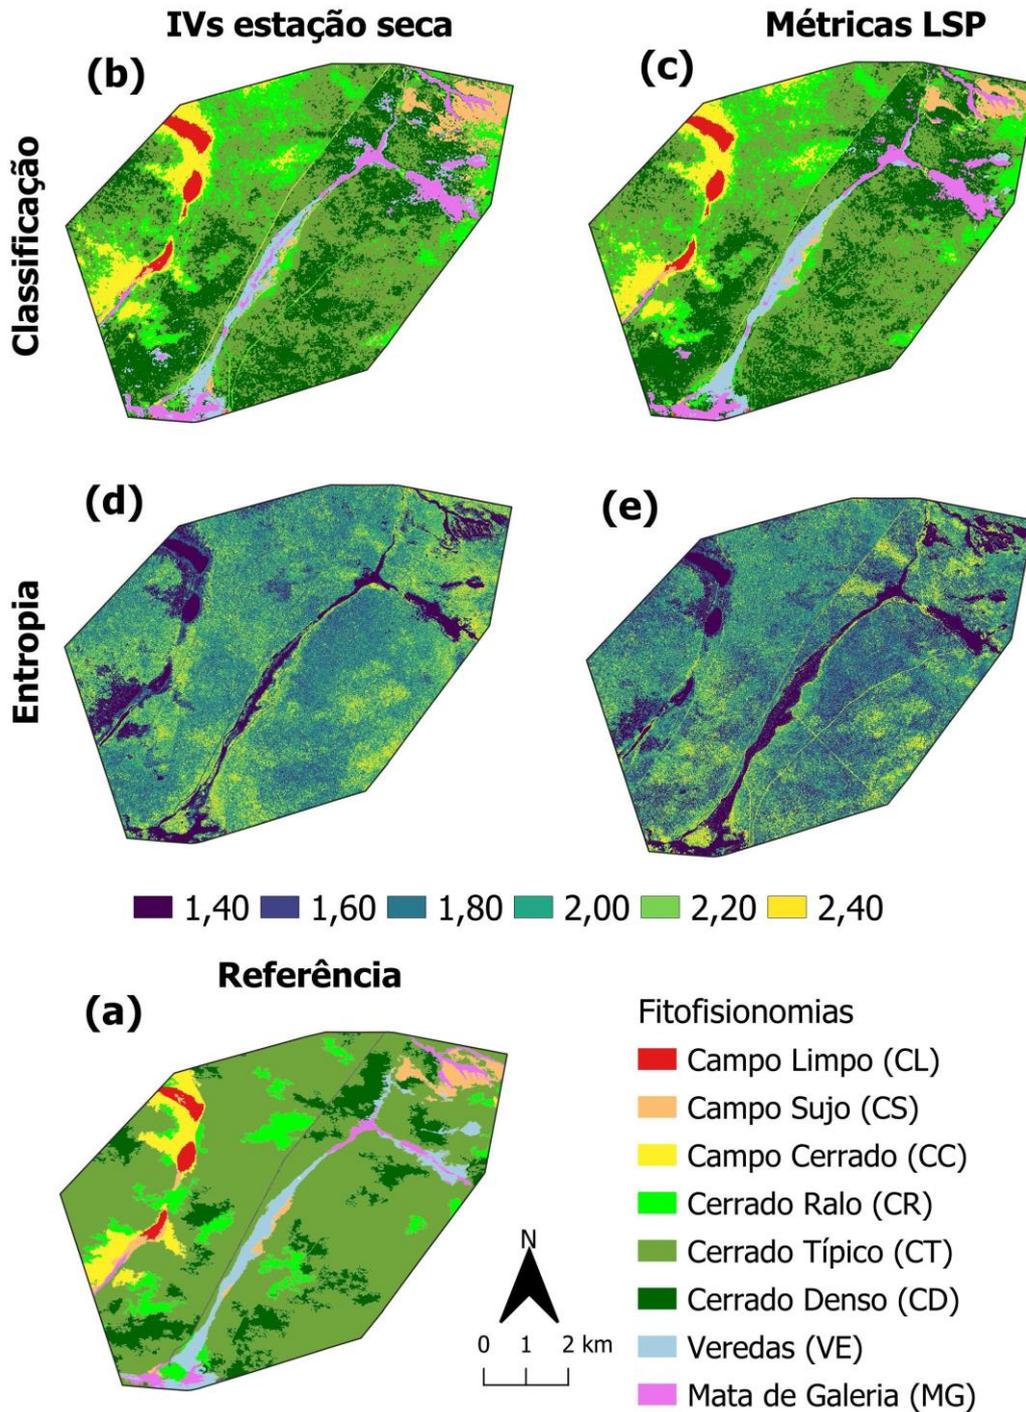


Fonte: Produção da autora.

Ambas as abordagens conjuntas (IVs da estação seca e métricas sazonais LSP) produziram mapas de classificação aproximadamente similares (Figura 5.8). Quando

comparados ao mapa de referência da vegetação da ESAE, concordâncias entre os resultados das classificações foram observadas. No entanto, a confusão na classificação foi principalmente associada à ocorrência das fitofisionomias CR e CT. Esses resultados foram consistentes com os baixos valores de *F1-score* reportados na Tabela 5.2 para ambas as fitofisionomias e abordagens conjuntas das variáveis.

Figura 5.8 - (a) Mapa da vegetação da Estação Ecológica de Águas Emendadas (ESAE). Classificação Random Forest da abordagem conjunta: (b) índices de vegetação na estação seca de 2017 e (c) métricas da fenologia da superfície (LSP) na estação de crescimento 2017-2018. As imagens de entropia correspondentes são apresentadas em (d) e (e), respectivamente.



Fonte: Adaptado de Geológica Ecothec (2009) e Jacon et al. (2017; 2021)

Fonte: Produção da autora.

Quando foram analisadas as incertezas associadas com a classificação Random Forest de ambas as abordagens combinando variáveis (IVs na estação seca e métricas LSP), observamos baixos valores de entropia (Figura 5.8 d; e) sobre áreas campestres e altos valores atribuídos sobre áreas de Cerrado Ralo e Denso (CR e CD). Isso foi expresso pela presença das cores azul e amarelo na imagem de entropia da Figura 5.8 (d; e), as quais representam a transição de baixa para alta incerteza na classificação. Em relação à classificação conjunta de IVs na estação seca, o uso conjunto das métricas LSP reduziu ligeiramente as incertezas na análise dos dados, como indicado pela quantidade comparativamente maior de pixels atribuídos às cores azuis na imagem de entropia LSP (Figura 5.8) e pelo gráfico boxplot apresentado na Figura C.1 (Apêndice C).

De forma geral, a entropia média na classificação conjunta dos IVs da estação seca foi de 1,94, cerca de 9% maior que a entropia média apresentada pela classificação com o uso conjunto de métricas LSP (1,85). Entre as fitofisionomias, a classificação RF baseada na estratégia conjunta de métricas LSP gerou menores incertezas na distinção de CD, VE e MG (Figura C.1). Por outro lado, o uso dos IVs da estação seca gerou menores incertezas apenas na classificação de CC, com diferença pouco significativa.

As confusões entre fitofisionomias para ambas as abordagens foram similares. Basicamente, o mesmo padrão reportado na classificação de uso individual das variáveis também foi observado na classificação combinada das métricas. As confusões ocorrem associadas ao gradiente transicional de cobertura vegetal, em sua maioria. CL, por exemplo, se confunde mais com CS nas duas estratégias da abordagem conjunta (estação seca e métricas LSP), assim como CC com CR; CR com CT; CT com CD; e, consequentemente, CD com CT. MG apresentou as maiores confusões associadas a VE. CS e VE foram as fitofisionomias em questão de diferença de adensamento que mostraram confusões. No entanto, elas ocorrem em associação na paisagem (Figura 5.8 a), pois CS está presente em áreas de borda de VE e MG.

Com base nas métricas mais importantes para a acurácia da classificação RF (Figura 5.7), foi verificado que a diferença média dos valores das métricas do NDVI e EVI entre as fitofisionomias que se confundem é menor que 0,05 (TRG, MSP, PEAK e MSG). Em contraste, as fitofisionomias que menos se confundem (CL com CT, CD e VE; CS e CC com MG) possuem diferenças médias entre as métricas maiores que 0,10.

6 DISCUSSÃO

A análise desenvolvida neste trabalho apresenta três importantes contribuições para o sensoriamento remoto de savanas no Brasil. Primeiro, os resultados confirmaram ganhos usando métricas LSP para aumentar a acurácia da classificação de fitofisionomias do Cerrado, especialmente de métricas calculadas a partir dos índices de vegetação NDVI e EVI. Por exemplo, quando comparado ao uso da informação de 12 imagens EVI do PS obtidas na estação seca, a classificação RF, usando a informação sazonal das métricas LSP derivada deste mesmo IV, produziu um aumento na OA de 0,57 para 0,68. Essa comparação de desempenho entre ambos os conjuntos de dados não foi reportada por nenhum trabalho em estudos prévios.

Como segunda contribuição do trabalho, os resultados demonstraram o potencial do uso combinado de diferentes IVs na estação seca, sensíveis a diferentes atributos biofísicos da vegetação de Cerrado. Esta estratégia é uma alternativa para a eventual inacessibilidade às séries temporais densas que impeçam o cálculo das métricas LSP. Essa abordagem produziu um OA de 0,70, ligeiramente menor que o resultado encontrado para o uso combinado de métricas LSP (0,73).

Finalmente, como última contribuição relevante a destacar, até o momento, esse é o primeiro estudo usando dados da constelação de satélites Planet sobre savanas no Brasil. Essa contribuição inovadora mostra que combinar dados PS de alta resolução espacial e temporal contribui para melhor lidar com a heterogeneidade da vegetação de Cerrado. A precisão da classificação provavelmente irá aumentar com a melhoria na resolução espectral da nova geração de CubeSats, especialmente com a inserção de bandas no infravermelho de ondas curtas (SWIR). No recente estudo publicado por Souza et al. (2021), os IVs derivados da banda do SWIR foram especialmente importantes para detectar distúrbios (desmatamento e fogo) sobre áreas de savana no Brasil.

Os resultados desta dissertação de mestrado estão em concordância com estudos anteriores feitos por Ferreira e Huete (2004) e Ratana et al. (2005). Estes foram os primeiros a sugerirem que a análise da dinâmica sazonal da vegetação poderia ser potencialmente útil para mapear savanas no Brasil. Eles também são concordantes com os apontamentos reportados por Schwieder et al. (2016). Eles mapearam fitofisionomias em algumas áreas do Cerrado usando a informação fenológica capturada da

transformação Tasseled Cap (TC), do algoritmo TIMESAT e de dados Landsat. Estes autores, entretanto, não quantificaram eventuais ganhos do uso da informação fenológica advinda da transformação TC, em relação a uma possível classificação focada apenas na estação seca. Isto foi objeto de análise desta dissertação de mestrado e com geração de métricas LSP a partir de IVs que não dependem da variância de cada cena, como é o caso da transformação TC.

O uso de métricas LSP determinadas pelo algoritmo *greenbrown* a partir de dados PS de EVI, NDVI e GRND produziram ganhos de classificação (OA) de 19,3%, 13,1% e 5,4%, respectivamente, quando comparado ao uso isolado de imagens IVs na estação seca. Tendo o EVI da estação seca como referência de comparação, o uso combinado de IVs e métricas LSP para a classificação RF proporcionou ganhos em OA de 22,8% e 28,1%, respectivamente. Esses resultados foram consistentes com aqueles encontrados por Souza et al. (2021), os quais indicam a importância do uso conjunto de IVs com diferentes sensibilidades a parâmetros biofísicos da vegetação para gerar alertas precoces de distúrbios no Cerrado usando o algoritmo *Change Detection And Classification*.

Assim, esta dissertação de mestrado evidenciou as vantagens da classificação sazonal LSP (estação de crescimento em 2017-2018) sobre a classificação feita apenas durante a estação seca de 2017 para mapear savanas no Brasil. Ela também comprovou as vantagens no emprego do uso combinado de IVs ou métricas LSP calculadas a partir destes índices, explorando atributos biofísicos distintos da vegetação de Cerrado. Usando métricas LSP conjuntas (derivadas dos três IVs), as variáveis mais importantes para a classificação RF foram: o valor mínimo (TRG) e máximo (PEAK) de IV; o valor médio na primavera (MSP) e na estação de crescimento (MGS); e a taxa de *green up* na primavera (RSP). Por exemplo, a métrica MGS derivada do EVI apresentou valores mais baixos em áreas campestres e mais altos em áreas florestais, enquanto RSP derivado do NDVI apresentou um comportamento oposto. Esse resultado era esperado, uma vez que as maiores taxas de mudanças em IVs ao longo das estações do ano foram associadas a Campo Limpo e Campo Sujo (JACON et al., 2017).

De forma geral, a classificação a partir das métricas LSP usadas de forma combinada proporcionou ganhos significativos na discriminação das fitofisionomias presentes na ESAE. Foi observada uma predominância de efeito “*salt and pepper*” devido à alta

heterogeneidade dos ecossistemas savânicos. O mesmo efeito foi reportado por Schwieder et al. (2016) utilizando dados com resolução espacial de 30 metros. Em relação aos resultados obtidos por Schwieder et al. (2016) na área da ESAE, os autores usaram uma legenda de classificação distinta da utilizada nesse trabalho, não incluindo, por exemplo, Veredas. Na estratégia apresentada aqui, o número de classes utilizado nesta dissertação foi, portanto, superior à vista neste trabalho.

Em mapeamento direcionado a fitofisionomias de Veredas, Bendini et al. (2021) verificaram que ao empregar a técnica de *deep learning* U-Net com base em 22 atributos extraídos de bandas espectrais de imagem Sentinel-2, os valores alcançados de *Precision* foram de 0,73 e 0,58 nas áreas de treinamento e sobre uma eco-região distinta para validação. O *F1-Score* foi de 0,72 e 0,24, para as respectivas áreas. Os resultados aqui apresentados foram superiores, sendo 0,70 e 0,89 de P para Veredas classificadas com uso conjunto de IVs da estação seca e métricas LSP, respectivamente. O *F1-score* aqui apresentado também foi superior (0,72 para 36 IVs na estação seca de 2017; e 0,87 para 36 métricas LSP no ciclo de crescimento 2017-2018). Bendini et al. (2021) apontaram algumas confusões entre Veredas e áreas de agricultura irrigada, o que pode ser superado levando-se em consideração o aspecto temporal, como os alcançados com as métricas fenológicas na presente dissertação.

Campo Sujo também apresentou baixa entropia associada a classificação, o que resultou em áreas bem classificadas. As maiores confusões foram observadas entre Cerrado Ralo, Típico e Denso. Uma alternativa para melhor discriminar essas fitofisionomias talvez seja a incorporação de aspectos contextuais. Trabalhos futuros devem incluir a informação contextual, pois ambientes savânicos são altamente heterogêneos. Algumas tipologias de vegetação ocorrem em associação com aspectos biofísicos da paisagem, o que pode elevar a capacidade da classificação, como a proximidade de corpos d'água e a presença de substratos rochosos (FONSECA et al., 2021).

Embora a constelação de satélites PS seja capaz de adquirir observações quase diárias sobre a ESAE, a cobertura de nuvens e sombras de nuvens ainda foram os principais problemas associados à análise dos dados. Frente às dificuldades encontradas na recuperação automática de dados de alta qualidade, a seleção de imagens sem nuvens gerou duas séries temporais espaçadas de forma diferente na área de estudo: uma para a

estação chuvosa e outra para a estação seca. Futuros estudos devem considerar procedimentos mais elaborados para a remoção de nuvens e sombras de nuvens, evitando lacunas desnecessárias na série temporal. Isso facilitará também o desempenho dos algoritmos interpoladores de dados. Ainda no rol de futuros estudos, destaca-se a importância de compor séries temporais mais longas, que capturem a variabilidade climática intra e interanual.

Complementar a isso, a exigência computacional no processamento dos dados Planet também foi considerada uma limitação. Em virtude da alta resolução espacial, a análise *pixel a pixel* foi onerosa e apresentou tempo elevado de processamento no cálculo das métricas fenológicas. Outra limitação foram os valores negativos associados ao GRND. Esse resultado não era esperado considerando a literatura, uma vez que a reflectância na banda do verde é geralmente mais elevada que a reflectância do vermelho sobre áreas de savanas densas ou matas de galeria. O problema provavelmente está associado às especificações das bandas dos sensores da geração PS2 de CubeSats. Para essa geração de dados PS, as bandas do visível mostraram um inesperado grau de sobreposição entre suas funções de filtros (funções de resposta). Como reportado por Breunig et al. (2020), essa questão parece ter sido resolvida na nova geração de CubeSats da Planet. Isso irá melhorar a qualidade de séries temporais para futuras investigações. Após a melhoria na resolução espectral dos sensores, outros índices de vegetação poderão ser explorados para reunir ao máximo informações de parâmetros biofísicos da vegetação que possam auxiliar na discriminação das fitofisionomias. Este é o caso dos IVs calculados com bandas do infravermelho de ondas curtas, que têm sido úteis para a detecção de distúrbios (Souza et al., 2021).

Por fim, não foi testado o desempenho de outros classificadores na análise dos dados, incluindo abordagens de *deep learning*. Recentemente, a abordagem *deep learning* foi usada para classificar savanas com dados WorldView-2 adquiridos na estação seca (Neves et al., 2021). No entanto, ao comparar diferentes técnicas sobre áreas de savana no Parque Nacional de Brasília, Toniol et al. (2017) indicaram o classificador RF como uma das mais promissoras técnicas para discriminar fisionomias usando grande número de métricas. Além disso, RF foi a técnica mais adequada para estimar a biomassa acima do solo sobre a ESAE, como demonstrado recentemente por Jacon et al. (2021). Neste contexto, devido ao número limitado de métricas utilizadas em nosso trabalho e a

necessidade de assegurar uma comparação justa entre os nossos conjuntos de dados, não aplicamos qualquer procedimento de seleção de variáveis sobre os dados antes da classificação RF. Algum grau de sobreposição dos resultados pode ser esperado.

7 CONCLUSÃO

Os resultados confirmam a hipótese que a informação sobre fenologia da vegetação (métricas LSP) aumenta a acurácia da classificação RF das fitofisionomias do Cerrado, quando comparado com a classificação usando somente dados de IVs da estação seca. Também confirmam a hipótese de que abordagens de classificação RF usando combinações de métricas (diferentes VIs ou suas métricas LSP combinadas) produzem ganhos em acurácia de classificação, quando comparado com o uso individual de variáveis. Assim, concluiu-se que:

- a) Quando comparada ao uso individual de IVs da estação seca de 2017, as métricas LSP determinadas para o ciclo de crescimento de 2017-2018 adicionaram ganhos na OA de 19,3%, 13,1% e 5,4% para EVI, NDVI e GRND, respectivamente. Portanto, a informação sazonal sobre fenologia da vegetação obtida da constelação de satélites PS contribuiu para melhorar a classificação das savanas.
- b) O uso conjunto dos IVs explorando diferentes atributos biofísicos das savanas, ou de suas métricas LSP, também proporcionou ganhos em OA. Por exemplo, usando a classificação EVI na estação seca como referência de comparação, ganhos na OA de 22,8% e 28,1% foram observados do uso conjunto de IVs ou da combinação de suas métricas LSP, respectivamente. Na ausência de séries temporais densas que não propiciem o cálculo adequado das métricas fenológicas para um dado sensor orbital (p.ex., Landsat ou Sentinel-2), os resultados indicam, como estratégia alternativa de classificação, o uso combinado de diferentes IVs na estação seca, um período mais favorável para adquirir imagens sem a presença de cobertura de nuvens.
- c) As métricas mais importantes para a classificação usando a abordagem conjunta de métricas LSP foram: os valores mínimos (TRG) e máximos (PEAK) de IV; os valores médios na primavera (MSP) e na estação de crescimento (MGS); e a taxa de *green up* na primavera (RSP). Isto foi válido especialmente para as métricas LSP calculadas do NDVI e EVI.

Portanto, os resultados destacam a importância dos dados da constelação de satélites da Planet, combinando alta resolução espacial com alta resolução temporal, para a classificação de savanas brasileiras usando a informação sobre fenologia da vegetação e

a combinação de variáveis preditoras. De forma complementar, a estratégia proposta também pode ser testada com a inserção de outras variáveis preditoras, como métricas de textura da imagem que podem variar sazonalmente em resposta às variações de cobertura vegetal, decorrentes da presença de indivíduos arbustivos e arbóreos, e de geometria de iluminação e visada dos CubeSats. A inclusão de dados multi-temporais oriundos de outros sensores (p.ex., radar e LiDAR), assim como a utilização de diferentes classificadores em abordagens conjuntas ou individuais, também podem ser explorados.

REFERÊNCIAS BIBLIOGRÁFICAS

- AB'SABER, A.N. A organização natural das paisagens inter e subtropicais brasileiras. In: SIMPÓSIO SOBRE O CERRADO, 1971, São Paulo. **Anais...** São Paulo: Edgard Blucher /EDUSP, 1971. p. 1-14.
- ALBUQUERQUE, L. G. Histórico. In: FONSECA, O. F. (Org.). **Águas emendadas**. 2. ed. Brasília: SEDUMA, 2008. p. 21-44.
- ALENCAR, A.; SHIMBO, J.Z.; LENTI, F.; MARQUES, C.B.; ZIMBRES, B.; ROSA, M.; ARRUDA, V.; CASTRO, I.; RIBEIRO, J.P.F.M.; VARELA, V.; ALENCAR, I.; PIONTEKOWSKI, V.; RIBEIRO, V.; BUSTAMANTE, M.; SANO, E.E.; BARROSO, M. Mapping three decades of changes in the brazilian savanna native vegetation using landsat data processed in the google earth engine platform. **Remote Sensing**, v. 12, n. 6, e924, 2020. Disponível em: <https://doi.org/10.3390/rs12060924>.
- ARCHER, E. **rfPermute**: estimate permutation p-values for tandom forest importance metrics v.2.1.6. Maryland, ML, USA: NOAA, 2018.
- ARVOR, D.; JONATHAN, M., MEIRELLES, M.S.P, DUBREUIL, V., DURIEUX, L. Classification of MODIS EVI time series for crop mapping in the state of Mato Grosso. **International Journal of Remote Sensing**, Brasil, v. 32, p. 7847-7871, 2011. Disponível em: <https://doi.org/10.1080/01431161.2010.531783>.
- BELGIU, M.; DRAGUT, L. Random forest in remote sensing: a review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24-31, 2016. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2016.01.011>.
- BENDINI, H.N.; FONSECA, L.M.G.; MARETTO, R.V.; MOTOSAK, B.M.; TAQUARY, E.C.; SIMÕES, P.S.; HAIDAR, R.F.; VALERIANO, D.M. Exploring a deep convolucional neural network and geobia for automatic recognition of brazilian palm swamps (veredas) using Sentinel-2 optical data. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2021. **Proceedings...** IEE, 2021. p. 5401-5404. Disponível em: <https://doi.org/10.1109/IGARSS47720.2021.9554050>.
- BENDINI, H.N.; FONSECA, L.M.G.; SCHWIEDER, M.; KORTING, T.S.; RUFIN, P.; SANCHES, I.D.A.; LEITÃO, P.J.; HOSTERT, P. Detailed agricultural land classification in the Brazilian cerrado based on phenological information from dense satellite image time series. **International Journal of Applied Earth Observation and Geoinformation**, v. 82, e101872, 2019. Disponível em: <https://doi.org/10.1016/j.jag.2019.05.005>.
- BERLINCK, C. N. **Diagnóstico socioambiental do entorno da Estação Ecológica de Águas Emendadas (DF)**. 2008. 154p. Tese (Doutorado em Ecologia) - Universidade de Brasília (UnB), Brasília, 2008. Disponível em: <http://www.bibliotecaflorestal.ufv.br/handle/123456789/8837>.
- BERGAMASCHI, H. O clima como fator determinante da fenologia das plantas. In: REGO, C.M.; NEGRELLE, R.R.B.; MORELATTO, L.P.C. (Ed). **Fenologia: ferramenta para conservação, melhoramento e manejo de recursos vegetais arbóreos**. Colombo: Embrapa Florestas, 2007. p. 291-310.

BISPO, P. D. C. et al. Woody aboveground biomass mapping of the Brazilian savanna with a multi-sensor and machine learning approach. **Remote Sensing**, v. 12, n. 17, 2020. Disponível em: <https://doi.org/10.3390/rs12172685>.

BORGES, E.F.; SANO, E.E. Temporal series of EVI from MODIS sensor for land use and land cover mapping of western Bahia. **Boletim de Ciências Geodésicas**, v. 20, p. 526-547, 2014. Disponível em: <https://doi.org/10.1590/S1982-21702014000200030>.

BRASIL. **Lei nº 12.651, de 25 de maio de 2012**. Dispõe sobre a proteção da vegetação nativa, altera as leis nos 6.938, de 31 de agosto de 1981, 9.393, de 19 de dezembro de 1996, e 11.428, de 22 de dezembro de 2006, revoga as leis nos 4.771, de 15 de setembro de 1965, e 7.754, de 14 de abril de 1989, e a medida provisória no 2.166-67, de 24 de agosto de 2001 e dá outras providências. Disponível em:

http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/112651.htm#:~:text=Esta%20Lei%20estabelece%20normas%20gerais%20sobre%20a%20prote%C3%A7%C3%A3o%20da%20vegeta%C3%A7%C3%A3o,e%20prev%C3%AA%20instrumentos%20econ%C3%B4micos%20e.

BRASIL. **Lei nº 9.985, de 18 de julho de 2000**. Regulamenta o art. 225, § 1º, incisos I, II, III, e VII da Constituição Federal, institui o Sistema Nacional de Unidades de Conservação da Natureza e dá outras providências. Disponível em:

http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/112651.htm#:~:text=Esta%20Lei%20estabelece%20normas%20gerais%20sobre%20a%20prote%C3%A7%C3%A3o%20da%20vegeta%C3%A7%C3%A3o,e%20prev%C3%AA%20instrumentos%20econ%C3%B4micos%20e.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5-32, 2001.

BREUNIG, F.M.; GALVÃO, L.S.; DALAGNOL, R.; DAUVE, C.E.; PARRAGA, A.; SANTI, A.L.; FLORA, D.P.D.; CHEN, S. Delineation of management zones in agricultural fields using cover-crop biomass estimates from PlanetScope data.

International Journal of Applied Earth Observation and Geoinformation, v. 85, 2020. Disponível em: <https://doi.org/10.1016/j.jag.2019.102004>.

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

CAPARROS-SANTIAGO, J.A.; RODRIGUEZ-GALIANO, V.; DASH, J. Land surface phenology as indicator of global terrestrial ecosystem dynamics: a systematic review.

ISPRS Journal of Photogrammetry and Remote Sensing, v. 171, p. 330-347, 2021. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2020.11.019>.

CHEN, J.M.; DENG, F.; CHEN, M. Locally adjusted cubic-spline capping for reconstructing seasonal trajectories of a satellite-derived surface parameter. **IEEE Transactions on Geoscience and Remote Sensing**, v. 44, p. 2230-2238, 2006.

Disponível em: <https://doi.org/10.1109/TGRS.2006.872089>.

CHENG, Y.; VRIELING, A.; FAVA, F.; MERONI, M.; MARSHALL, M.; GACHOKI, S. Phenology of short vegetation cycles in a Kenyan rangeland from PlanetScope and Sentinel-2. **Remote Sensing of Environment**, v. 248, e112004, 2020. Disponível em: <https://doi.org/10.1016/j.rse.2020.112004>.

- COE, M.T.; COSTA, M.H.; SOARES-FILHO, B.S. The influence of historical and potential future deforestation on the stream flow of the Amazon River – land surface process and atmospheric feedbacks. **Journal of Hydrology**, v. 326, p.165-174, 2009. Disponível em: <https://doi.org/10.1016/j.jhydrol.2009.02.043>.
- DALAGNOL, R.; PHILLIPS, O.L.; GLOOR, E.; GALVÃO, L.S.; WAGNER, F.H.; LOCKAS, C.J.; ARAGÃO, L.E.O.C. Quantifying canopy tree loss and gaps recovery in tropical forests under low-intensity logging using VHR satellite imagery and airborne LiDAR. **Remote Sensing**, v. 11, n. 817, 2019. Disponível em: <https://doi.org/10.3390/rs11070817>.
- DANTAS, V.L.; BATALHA, M.A.; PAUSAS, J.G. Fire drives functional thresholds on the savanna-forest transition. **Ecology**, n. 94, v. 11, p. 2454-2463, 2013. Disponível em: <https://doi.org/10.1890/12-1629.1>.
- DURIGAN, G.; RATTER, J.A. The need for a consistent fire policy for Cerrado conservation. **Journal of Applied Ecology**, v. 53, p. 11-15, 2016. Disponível em: <https://doi.org/10.1111/1365-2664.12559>.
- EITEN, G. Brazilian savannas. **Ecological Studies**, v. 42, p. 25-47, 1982. Disponível em: <https://doi.org/10.1590/0001-3765202120210879>.
- EITEN, G. Physiognomic categories of vegetation. In: MIYAWAKI, A.; BOGENRIEDER, A.; OKUDA, S.; WHITE, J. (Ed.). **Vegetation ecology and creation of new environments**. Tokio: Tokai University Press, 1987. p.387-403.
- EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. **Correção do solo e adubação no sistema de plantio direto nos cerrados**. Rio de Janeiro: Embrapa Solos, 2003. p.22.
- FERREIRA, L.G.; ASNER, G.P.; KANAPP, D.E.; COE, M.; BUSTAMANTE, M.M.C.; 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, p. 7423-7440, 2011. Disponível em: <https://doi.org/10.1080/01431161.2010.523731>.
- FERREIRA, L.G.; HUETE A.R. Assessing the seasonal dynamics of the Brazilian Cerrado vegetation through the use of spectral vegetation indices. **International Journal of Remote Sensing**, v. 25, p. 1837–1860, 2004. Disponível em: <https://doi.org/10.1080/0143116031000101530>.
- FERREIRA, M.E. **Análise do modelo linear de mistura espectral na discriminação de fitofisionomias do Parque Nacional de Brasília (Biomass Cerrado)**. 2003. 96p. Dissertação (Mestrado em Geologia) - Universidade de Brasília (UnB), Brasília, 2003.
- FIDELIS, A.; ROSALEM, P.; ZANZARINI, V.; CAMARGOS, L.S.; MARTINS, A.R. From ashes to flowers: a savanna sedge initiates flowers 24 h after fire. **Ecology**, v.100, n.5, 2019. Disponível em: <https://doi.org/10.1002/ecy.2648>.
- FELFILI, J.M.; SILVA JÚNIOR, M.C.S.; MENDONÇA, R.C.; FAGG, C.W.; FILGUEIRAS, T.S.; MECENAS, V. Composição florística da Estação Ecológica de Águas Emendadas no Distrito Federal. **Heringeriana**, v. 1, p. 25-85, 2007. Disponível em: <https://dx.doi.org/10.17648/heringeriana.v1i2.126>.

- FLORES, B.M. et al. Tropical riparian forests in danger from large savanna wildfires. **Journal of Applied Ecology**, v. 58, n. 2, p. 419-430, 2020. Disponível em: <http://dx.doi.org/10.1111/1365-2664.13794>.
- FOLKER, M.; CARVALHAIS, N.; VERBESSELT, J.; MAHECHA, M.; NEIGH, C.; REICHSTEIN, M. Trend change detection in NDVI Time Series: effects of inter-annual variability and methodology. **Remote Sensing**, v. 5, n. 5, p. 2113–2144, 2013. Disponível em: <https://doi.org/10.3390/rs5052113>.
- FORKEL, M.; MIGLIAVACCA, M.; THONICKE, K.; REICHSTEIN, M.; SCHAPHOFF, S.; WEBER, U.; CARVALHAIS, N. Codominant water control on global interannual variability and trends in land surface phenology and greenness. **Global Change Biology**, v. 21, n. 9, p. 3414–3435, 2015. Disponível em: <https://doi.org/10.1111/gcb.12950>.
- FORKEL, M.; WUTZLER, T. **GreenBrown** - land surface phenology and trend analysis. A package for the R software. Version 2.2. 2015.
- GISLASON, P.O.; BENEDIKTSSON, J.A.; SVEINSSON, J.R. Random Forest for land cover classification. **Pattern Recognition Letters**, v. 27, n. 4, p. 294-300, 2006. Disponível em: <https://doi.org/10.1016/j.patrec.2005.08.011>.
- GEOLOGICA ECOTECH. **Plano de manejo**: programa de proteção, planejamento e gestão para a Estação Ecológica de Águas Emendadas (ESEC-AE). Brasília: Instituto Brasília Ambiental, IBRAM, 2009.
- GONÇALVES, L.M.; FONTE, C.C.; JÚLIO, E.N.B.S.; CAETANO, M. Evaluation of remote sensing images classifiers with uncertainty measures. In: RODOLPHE, D., HELEN, G. (Ed.). **Spatial data quality from process to decisions**. Boca Raton: CRC Press, 2009. p.163-177. Disponível em: <https://doi.org/10.1201/b10305-19>.
- GRAY, R. **Entropy and information theory**, 2. ed. Springer, New York. 2011. 291p.
- GU, L.; POST, W.M.; BALDOCCHI, D.; BLACK, T.A.; VERMA, S.B.; VESALA, T.; WOFSY, S.C. Phenology of vegetation photosynthesis. In: SCHWARTZ, M.D. (Ed.). **Phenology: an integrative environmental science. tasks for vegetation science**, Berlin: Springer, 2009. Disponível em: https://doi.org/10.1007/978-94-007-0632-3_29.
- HELDER, D.; ANDERSON, C.; BECKETT, K.; HOUBORG, R.; ZULETA, I.; BOCCIA, V.; CLERC, S.; KUESTER, M.; MARKHAM, B.; PAGNOUTTI, M. Observation and recommendations for coordinated calibration activities of government and comercial optical satellite systems. **Remote Sensing**, n. 12, v. 15, 2020. Disponível em: <https://doi.org/10.3390/rs12152468>.
- HOUBORG, R.; MCCABE, M.F. Daily retrieval of NDVI and LAI at 3 m resolution via the fusion of CubeSat, Landsat, and MODIS data. **Remote Sensing**, v. 10, n. 6, p. 890, 2018. Disponível em: <https://doi.org/10.3390/rs10060890>.
- HUETE, A.R.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E.P.; GAO, X.; FERREIRA, L.G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1, p. 195-213, 2002. Disponível em: [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2).
- INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). FIP CERRADO. **PRODES**: monitoramento da Floresta Amazônica Brasileira por satélite. Disponível

em: <https://www.gov.br/inpe/pt-br/assuntos/ultimas-noticias/nota-tecnica-prodes-cerrado-2021> . Acesso em: 20 jan. 2022.

JACON, A.D.; GALVÃO, L.S.; DALAGNOL, R.; SANTOS, J.R. Aboveground biomass estimates over Brazilian savannas using hyperspectral metrics and machine learning models: experiences with Hyperion/EO-1. **GIScience & Remote Sensing**, n. 58, v. 7, p. 1112-1129, 2021. Disponível em: <http://dx.doi.org/10.1080/15481603.2021.1969630>.

JACON, A.D.; GALVÃO, L.S.; SANTOS, J.R.; SANO, E.E. Seasonal characterization and discrimination of savannah physiognomies in Brazil using hyperspectral metrics from Hyperion/EO-1. **International Journal of Remote Sensing**, v. 38, n. 15, p. 4494-4516, 2017. Disponível em: <https://doi.org/10.1080/01431161.2017.1320443>.

JHON, A.; ONG, J.; THEOBALD, E.J.; OLDEN, J.D.; TAN, A.; HILLERISLAMBERS, J. Detecting montane flowering phenology with CubeSat imagery. **Remote Sensing**, v. 12, n. 18, 2020. Disponível em: <https://doi.org/10.3390/rs12182894>.

KIMBALL, J. Vegetation phenology. In: NJOKU, E.G. (Ed.). **Encyclopedia of remote sensing. encyclopedia of Earth sciences series**. New York: Springer, 2014. Disponível em: https://doi.org/10.1007/978-0-387-36699-9_188.

KLINK, C.A.; MACHADO, R.B. A conservação do Cerrado brasileiro. **Megadiversidade**, v. 1, n. 1, p. 147-155, 2005.

LACERDA, M. P. C. Meio físico: solos. In: FONSECA, F. O. (Org.). **Águas emendadas**. Brasília: SEDUMA, 2008. p.140-147.

LIAW, A.; WIENER, M. Classification and regression by Random Forest. **R News**, n. 2, p. 8-22, 2002.

LIESENBERG, V., GALVÃO, L.S., PONZONI, F.J. Variations in reflectance with seasonality and viewing geometry: implications for classification of Brazilian savanna physiognomies with MISR/terra data. **Remote Sensing of Environment**, v. 107, n. 1-2, p. 276-286, 2007. Disponível em: <https://doi.org/10.1016/j.rse.2006.03.018>

LIMA, J.E.F.W. Situação e perspectivas sobre as águas do cerrado. **Ciência e Cultura**, v. 63, n. 3, p. 27-29, 2011.

MAIA, J. M. F.; BAPTISTA, G. M. M. Meio físico: clima. In: FONSECA, F. O. (Org.). **Águas emendadas**. Brasília: SEDUMA, 2008. p.101-109.

MALHEIROS, R. A influência da sazonalidade na dinâmica da vida no bioma Cerrado. **Revista Brasileira de Climatologia**, v. 19, n. 12, p. 113-128, 2016.

MARACAHIPES-SANTOS, L.; SILVÉRIO, D.V.; MACEDO, M.N.; MARACAHIPES, L.; JANKOWSKI, J.; PAOLUCCI, L.N., NEILL, C.; BRANDO, P.M. Agricultural land-use change alters the structure and diversity of Amazon riparian forests. **Biological Conservation**, v. 252, 2020. Disponível em: <https://doi.org/10.1016/j.biocon.2020.108862>.

MOURA, Y.M.; GALVÃO, L.S.; HILKER, T., WU, J.; SALESKA, S.; AMARAL, C.H.; NELSON, B.W.; LOPES, A.P.; WIEDEMAN, K.K.; PROHASKA, N.; OLIVEIRA, R.C.; MACHADO, C.B.; ARAGÃO, L.E.O.C. 2017. Spectral analysis of amazon canopy phenology during the dry season using a tower hyperspectral camera

and modis observations. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 131, p. 52-64. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2017.07.006>.

MUNHOZ, C.B.R.; RIBEIRO, J.F. Veredas. In: FONSECA, O.F. (Org.). **Águas emendadas**. 2.ed. Brasília: SEDUMA, 2008. p.21-44.

MYERS, E.; KEREKES, J.; DAUGHTRY, C.; RUSS, A. Assessing the impact of satellite revisit rate on estimation of corn phenological transition timing through shape model fitting. **Remote Sensing**, v. 11, n. 21, 2019. Disponível em: <https://doi.org/10.3390/rs11212558>.

MYERS, N.; MITTERMEIER, R.A.; MITTERMEIER, C.G.; FONSECA, G.A.B.; KENT, J. Biodiversity hotspots for conservation priorities. **Nature**, 403, p. 853–858, 2000. Disponível em: <https://doi.org/10.1038/35002501>.

NAGEL, G.W.; NOVO, E.M.L.M.; KAMPEL, M. Nanosatellites applied to optical Earth observation: a review. **Ambiente & Água**, v. 15, n. 3, p. 1-19, 2020. Disponível em: <https://doi.org/10.4136/ambi-agua.2513>.

NEVES, A.K.; KORTING, T.S.; FONSECA, L.M.G.; SOARES, A.R.; GIROLAMONETO, C.D.; HEIPKE, C. Hierarchical mapping of Brazilian savanna (Cerrado) physiognomies based on deep learning. **Journal of Applied Remote Sensing**, v. 15, n. 4, p. 1-23, 2021. Disponível em: <https://doi.org/10.1117/1.JRS.15.044504>.

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, 2002. p.91–120.

PIVELLO, V.R. Invasões biológicas no Cerrado brasileiro: efeitos da introdução de espécies exóticas sobre a biodiversidade. **Ecologia.Info**, n.33, 2011a. Disponível em: <https://ecologia.info/cerrado.htm> . Acesso em: 17 jan. 2020

PIVELLO, V.R. The use of fire in the Cerrado and Amazonian Rainforests of Brazil: past and present. **Fire Ecology**, n. 7, v. 1, p.24-39, 2011b.

PLANET TEAM. Planet Surface Reflectance Product v2. Planet Labs, Inc. 2020. Disponível em: https://assets.planet.com/marketing/PDF/Planet_Surface_Reflectance_Technical_White_Paper.pdf . Acesso em: 31 jan de 2020.

PONZONI, F.J.; SHIMABUKURO, Y.E.; KUPLICH, T.M. **Sensoriamento remoto da vegetação**. 2. ed. São Paulo: Oficina de Texto, 2012. 178p.

RATANA, P.; HUETE, A.R.; FERREIRA, L. Analysis of cerrado physiognomies and conversion in the MODIS seasonal-temporal domain. **Earth Interactions**, v. 9, p. 1-22, 2005. Disponível em: [https://doi.org/10.1175/1087-3562\(2005\)009%3C0001:AOC PAC%3E2.0.CO;2](https://doi.org/10.1175/1087-3562(2005)009%3C0001:AOC PAC%3E2.0.CO;2).

RATTER, J.A.; BRIDGEWATER, S.; RIBEIRO, J.F. Biodiversity patterns of the woody vegetation of the Brazilian Cerrados. In: OLIVEIRA, P.S.; MARQUIS, R. J. (Ed.). **Neotropical savannas and seasonally dry forests**. London: Taylor & Francis. 2006. p. 31–66.

REZENDE, A.V.; PAPA, D.A. Revegetação natural de áreas antropizadas. In: FONSECA, O. F. (Org.). **Águas emendadas**. 2.ed. Brasília: SEDUMA, 2008. p. 21-44.

RIBEIRAO R.; ROCHA, C.R.; MARINHO-FILHO, J. Natural history and demography of *Thalpomys lasiotis* (Thomas, 1916), a rare and endemic species from the Brazilian savanna. **Acta Theriologica**, v. 56, n. 3, p. 275-282, 2011. Disponível em: <https://doi.org/10.1007/s13364-011-0026-0>.

RIBEIRO, J.F.; WALTER, B.M.T. Fitofisionomias do bioma Cerrado. In: SANO, S. M.; ALMEIDA, S. P. (Ed.). **Cerrado: ambiente e flora**. Planaltina, EMBRAPA, 1998. p.87–166.

ROUSE, J.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with erts. **NASA Special Publication**, v. 351, n. 1974, p. 309–317, 1973.

SADEH, Y.; ZHU, X.; DUNKERLEY, D.; WALKER, J.P.; ZHANG, Y.; ROZENSTEIN, O.; MANIVASAGAM, V.S.; CHENU, K. Fusion os Sentinel-2 and PlanetScope time-series data into daily 3 m surface reflectance and wheat LAI monitoring. **International Journal of Applied Earth Observations and Geoinformation**, n. 96, p. 1-14, 2021. Disponível em: <https://doi.org/10.1016/j.jag.2020.102260>.

SANO, E.E.; FERREIRA, L.G.; HUETE, A.R. Synthetic aperture radar (L-band) and optical vegetation indices for discriminating the Brazilian savanna physiognomies: a comparative analysis. **Earth Interactions**, v. 9, n. 15, p. 1-15, 2005. Disponível em: <https://doi.org/10.1175/EI117.1>.

SANO, E.E.; ROSA, R.; BRITO, J.R.; FERREIRA, L.G. Land cover mapping of the tropical savanna region in Brazil. **Environmental Monitoring and Assessment**, v. 166, p. 113-124. 2010. Disponível em: <https://doi.org/10.1007/s10661-009-0988-4>.

SANO, E.D.; RODRIGUES, A.A.; MARTINS, E.S.; BETTIOL, G.M.; BUSTAMANTE, M.M.C.; BEZERRA, A.S.; COUTO, A.F.; VASCONCELOS, J.S.; BOLFE, E.L. Cerrado ecoregions: a spatial framework to assess and prioritize Brazilian savanna environmental diversity for conservation. **Journal of Environmental Management**, v. 232, p. 818-828, 2019a. Disponível em: <https://doi.org/10.1016/j.jenvman.2018.11.108>.

SANO, E. E. et al. Land use dynamics in the Brazilian Cerrado in the period from 2002 to 2013. **Pesquisa Agropecuária Brasileira**, v. 54, p. 1-5, 2019b. Disponível em: <https://doi.org/10.1590/S1678-3921.pab2019.v54.00138>.

SARMIENTO, G. The Savannas of Tropical America. In: BOURLIÈRE, F. (Ed.). **Tropical Savannas**. New York, NY: Elsevier, 1983. p.245-288.

SCHWIEDER, M.; LEITÃO, P.J.; BUSTAMANTE, M.M.C.; FERREIRA, L.G.; RABE, A.; HOSTERT, P. Mapping Brazilian savanna vegetation gradients with Landsat time series. **International Journal of Applied Earth Observation and Geoinformation**, v. 52, p. 361-370, 2016. Disponível em: <https://doi.org/10.1016/j.jag.2016.06.019>.

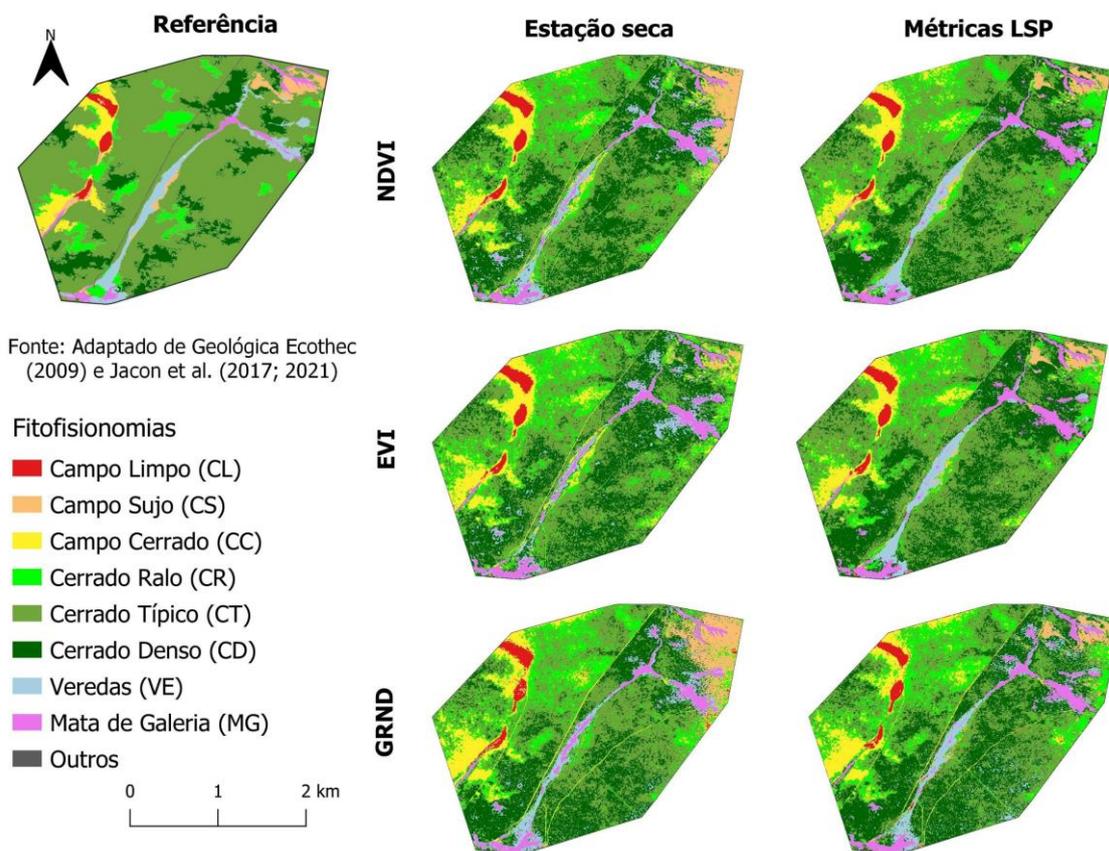
SOUZA, A.A.; GALVÃO, L.S.; KORTING, T.S.; ALMEIDA, C.A. On a data-driven approach for detecting disturbance in the Brazilian savannas using time series of vegetation indices. **Remote Sensing**, n. 13, v. 24, p. 1-20, 2021. Disponível em: <https://doi.org/10.3390/rs13244959>.

- SOUZA, A.A.; GALVÃO, L.S.; KORTING, T.S.; PRIETO, J.D. Dynamics of savanna clearing and land degradation in the newest agricultural frontier in Brazil. **GIScience & Remote Sensing**, v. 57, n. 7, p. 965-984, 2020. Disponível em: <https://doi.org/10.1080/15481603.2020.1835080>.
- SOUZA MENDES, F.; BARON, D.; GEROLD, G.; LIESENBERG, V.; ERASMI, S. Optical and SAR remote sensing synergism for mapping vegetation types in the endangered Cerrado/Amazon types in the endangered Mutum – Mato Grosso. **Remote Sensing**, v. 11, n. 10, p. 1161, 2019. Disponível em: <https://doi.org/10.3390/rs11101161>.
- TATEISHI, R.; EBATA, M. Analysis of phenological change patterns using 1982–2000 Advanced Very High Resolution Radiometer (AVHRR) data. **International Journal of Remote Sensing**, v. 25, n. 12, p. 2287-2300, 2004. Disponível em: <https://doi.org/10.1080/01431160310001618455>.
- TONIOL, A.C.; GALVÃO, L.S.; PONZONI, F.J.; SANO, E.E.; AMORE, D.J. Potential of hyperspectral metrics and classifiers for mapping Brazilian savannas in the rainy and dry seasons. **Remote Sensing Applications: Society and Environment**, v. 8, p. 20-29, 2017. Disponível em: <https://doi.org/10.1016/j.rsase.2017.07.004>.
- TRANCOSO, R.; SANO, E.E.; MENESES, P.R. The spectral change of deforestation in the Brazilian tropical savanna. **Environmental Monitoring Assessment**, v. 187, 4145, 2015. Disponível em: <https://doi.org/10.1007/s10661-014-4145-3>.
- TRIGUEIRO, W.R.; NABOUT, J.C.; TESSAROLO, G. Uncovering the spatial variability of recent deforestation drivers in the Brazilian Cerrado. **Journal of Environmental Management**, v. 275, n. 1, p. 1-10, 2020. Disponível em: <https://doi.org/10.1016/j.jenvman.2020.11124>.
- WALTER, H. **Vegetação e zonas climáticas**. São Paulo, EPU, 1986, 325p.
- WANG, J.; YANG, D.; DETTO, M.; NELSON, B.M.; CHEN, M.; GUAN, K.; WU, S.; YAN, Z.; WU, J. Multi-scale integration of satellite remote sensing improves characterization of dry-season green-up in an Amazon tropical evergreen forest. **Remote Sensing of Environment**, v. 246, p. 1-16, 2020. Disponível em: <https://doi.org/10.1016/j.rse.2020.111865>.
- WU, S.; WANG, J.; YAN, Z.; SONG, G.; CHEN, Y.; MA, Q.; DENG, M.; WU, Y. Monitoring tree-crown scale autumn leaf phenology in a temperate forest with an integration of PlanetScope and drone remote sensing observations. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 171, p. 36-48, 2021. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2020.10.017>.
- XUEYING, L.; ZHU, W.; XIE, Z.; ZHAN, P.; HUANG, X.; SUN, L.; DUAN, Z. Assessing the effects of time interpolation of NDVI composites on phenology trend estimation. **Remote Sensing**, v. 13, n. 24, p. 1-19, 2021. Disponível em: <https://doi.org/10.3390/rs13245018>.
- ZENG, L.; WARDLOW, B.D.; XIANG, D.; HU, S.; LI, D. A review of vegetation phenological metrics extraction using time-series, multispectral satellite data. **Remote Sensing of Environment**, v. 237, e111511, 2020. Disponível em: <https://doi.org/10.1016/j.rse.2019.111511>.

ZONATTA, D.C.; FERREIRA, M.P. ZOTEA, M. **Processamento de imagens de satélite**. São Paulo: Oficina de Textos, 2019.

APÊNDICE A – CLASSIFICAÇÃO RANDOM FOREST A PARTIR DO USO ISOLADODO DAS VARIÁVEIS

Figura A.1 - Classificação RF de IVs da estação seca (2017) e métricas LSP (estação de crescimento 2017-2018) a partir de IVs isolados (abordagem não conjunta).



Fonte: Produção da autora.

APÊNDICE B – MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO RF DA ESTAÇÃO SECA E MÉTRICAS LSP POR IV ISOLADO

Tabela B.1 - NDVI da estação seca de 2017.

	Referência							
	CL	CS	CC	CR	CT	CD	VE	MG
CL	287	23	10	1	0	0	1	0
CS	4	123	26	42	19	6	18	0
CC	9	46	201	60	10	1	34	0
CR	0	36	45	102	38	6	20	1
CT	0	27	12	45	137	67	12	0
CD	0	17	0	35	83	164	25	10
VE	0	12	1	12	12	44	204	42
MG	0	5	0	3	1	12	76	345
OA	0,61							

Fonte: Produção da autora.

Tabela B.2 – EVI da estação seca de 2017.

	Referência							
	CL	CS	CC	CR	CT	CD	VE	MG
CL	284	17	10	1	0	0	1	0
CS	3	98	19	31	24	5	20	0
CC	13	69	215	63	5	0	28	0
CR	0	34	40	95	39	11	20	1
CT	0	29	7	66	134	86	40	2
CD	0	31	1	28	82	134	51	11
VE	0	9	3	14	16	53	145	32
MG	0	2	0	2	0	11	85	352
OA	0,57							

Fonte: Produção da autora.

Tabela B.3 – GRND da estação seca de 2017.

	Referência							
	CL	CS	CC	CR	CT	CD	VE	MG
CL	245	30	50	19	7	1	1	1
CS	16	139	2	13	24	12	7	5
CC	23	24	193	74	16	2	3	0
CR	9	17	35	88	30	10	7	0
CT	2	31	12	66	148	89	15	2
CD	1	18	1	26	53	115	35	9
VE	4	18	2	13	21	54	204	68
MG	0	12	0	1	1	17	118	313
OA	0,56							

Fonte: Produção da autora.

Tabela B.4 – NDVI métricas LSP (ciclo de crescimento 2017-2018).

	Referência							
	CL	CS	CC	CR	CT	CD	VE	MG
CL	283	15	7	0	0	0	1	0
CS	1	167	11	12	6	6	14	0
CC	16	27	215	70	12	1	5	0
CR	0	17	42	108	39	15	3	0
CT	0	21	20	69	159	86	2	1
CD	0	22	0	29	81	162	6	15
VE	0	18	0	11	3	12	326	29
MG	0	2	0	1	0	18	33	353
OA	0,69							

Fonte: Produção da autora.

Tabela B.5 – EVI métricas LSP (ciclo de crescimento 2017-2018).

	Referência							
	CL	CS	CC	CR	CT	CD	VE	MG
CL	282	16	15	2	0	0	0	0
CS	6	172	10	8	5	3	14	0
CC	11	17	214	80	11	3	2	0
CR	1	21	47	91	55	8	5	0
CT	0	14	6	63	117	67	0	1
CD	0	13	2	46	105	192	8	16
VE	0	28	1	8	4	7	327	27
MG	0	8	0	2	3	20	34	354
OA	0,68							

Fonte: Produção da autora.

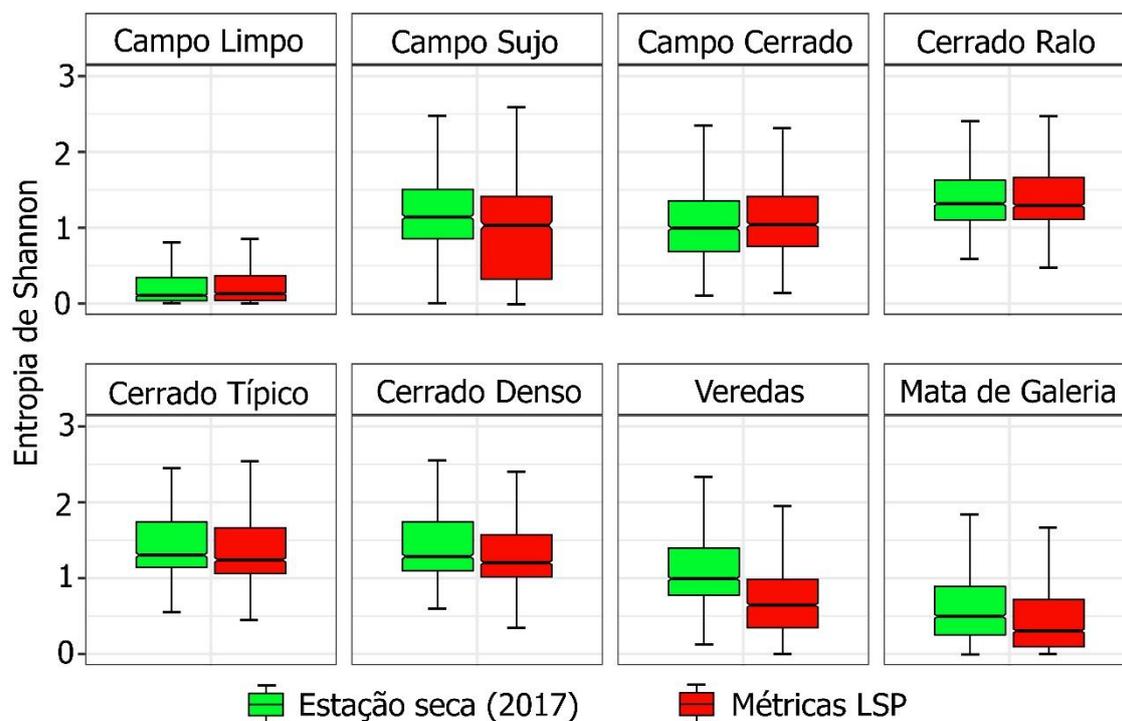
Tabela B.6 – GRND métricas LSP (ciclo de crescimento 2017-2018).

	Referência							
	CL	CS	CC	CR	CT	CD	VE	MG
CL	249	22	22	16	3	0	14	0
CS	10	135	3	15	16	7	20	3
CC	25	32	192	89	16	4	1	0
CR	6	17	44	85	40	17	7	1
CT	0	21	26	46	114	66	28	7
CD	0	19	4	24	71	124	32	15
VE	10	40	4	23	38	57	253	24
MG	0	3	0	2	2	25	35	348
OA	0,58							

Fonte: Produção da autora.

APÊNDICE C - VALORES DE ENTROPIA POR FITOFISIONOMIAS PARA AS CLASSIFICAÇÕES DE USO COMBINADO DE VARIÁVEIS DA ESTAÇÃO SECA (36 IVs) E MÉTRICAS LSP (36 MÉTRICAS LSP)

Figura C.1 - Boxplot entropia de Shannon por fitofisionomia savânica.



Fonte: Produção da autora.