



Universidade do Estado do Rio de Janeiro

Mateus Benchimol Ferreira de Almeida

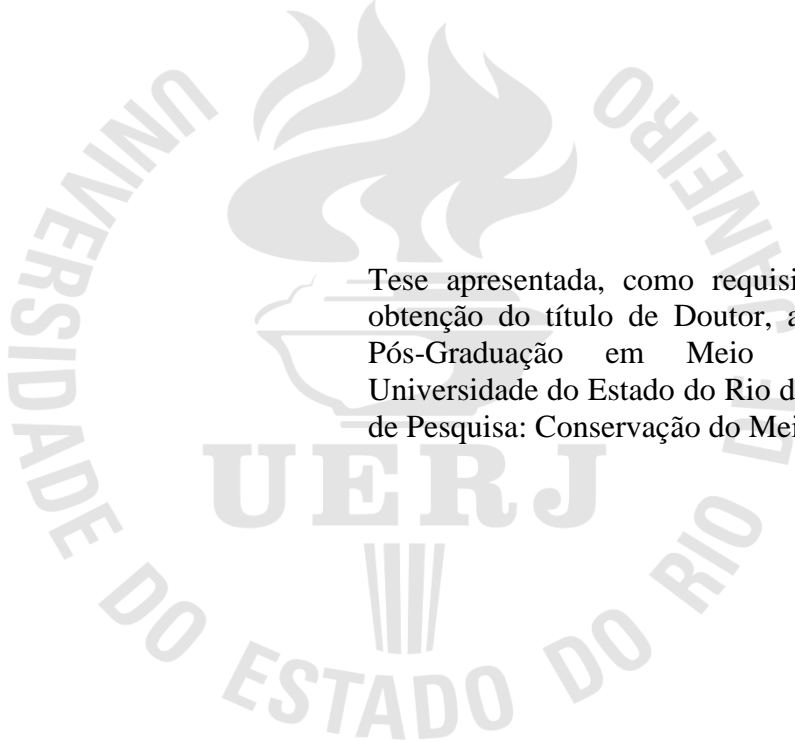
Métodos de sensoriamento remoto orbital para o diagnóstico e monitoramento dos níveis de degradação de pastagens tropicais: uma contribuição ao plano de agricultura de baixa emissão de carbono

Rio de Janeiro

2022

Mateus Benchimol Ferreira de Almeida

A Métodos de sensoriamento remoto orbital para o diagnóstico e monitoramento dos níveis de degradação de pastagens tropicais: uma contribuição ao plano de agricultura de baixa emissão de carbono



Tese apresentada, como requisito parcial para obtenção do título de Doutor, ao Programa de Pós-Graduação em Meio Ambiente, da Universidade do Estado do Rio de Janeiro. Linha de Pesquisa: Conservação do Meio Ambiente.

Orientadora: Prof.^a Dra. Margareth Simões

Coorientador: Dr. Rodrigo Peçanha Demonte Ferraz

Rio de Janeiro

2022

CATALOGAÇÃO NA FONTE
UERJ / REDE SIRIUS / BIBLIOTECA CTC-A

A447 Almeida, Mateus Benchimol Ferreira de.
Métodos de sensoriamento remoto orbital para o diagnóstico e monitoramento dos níveis de degradação das pastagens tropicais: uma contribuição ao plano de agriculturade baixa emissão de carbono / Mateus Benchimol Ferreira de Almeida. – 2022.
160f. : il.


Orientadora: Margareth Simões.
Coorientador: Rodrigo Peçanha Demonte Ferraz.
Tese (Doutorado em Meio Ambiente) - Universidade do Estado do Rio de Janeiro, Universidade do Estado do Rio de Janeiro.

1. Degradação ambiental - Valença (RJ) - Teses. 2. Vegetação - Valença (RJ) - Teses. 3. Senoriamento remoto - Valença (RJ) - Teses. 4. Cerrados - Brasil - Teses. I. Simões, Margareth. II. Ferraz, Rodrigo Peçanha Demonte. III. Universidade do Estado do Rio de Janeiro. IV. Título

CDU 504.03(815.3)

Patricia Bello Meijinhos CRB7/5217 - Bibliotecária responsável pela elaboração da ficha catalográfica

Autorizo para fins acadêmicos e científicos, a reprodução total ou parcial desta tese, desde que citada a fonte



Assinatura

08/12/2022

Data

Mateus Benchimol Ferreira de Almeida

Métodos de sensoriamento remoto orbital para o diagnóstico e monitoramento dos níveis de degradação de pastagens tropicais: uma contribuição ao plano de agricultura de baixa emissão de carbono

Tese apresentada, como requisito parcial para obtenção do título de Doutor, ao Programa de Pós-Graduação em Meio Ambiente, da Universidade do Estado do Rio de Janeiro. Linha de Pesquisa: Conservação do Meio Ambiente.

Aprovado em 29 de junho de 2022.

Banca Examinadora:

Prof.^a Dra. Margareth Simões (Orientadora)
Departamento de Engenharia de Sistemas e Computação - UERJ

Dr. Rodrigo Peçanha Demonte Ferraz (Coorientador)
Embrapa Solos

Prof. Dr. Matheus Pinheiro Ferreira
Instituto Militar de Engenharia - IME

Prof. Dr. Damien Arvor
Centre National de la Recherche Scientifique - CNRS (França)

Dr. Pedro Luiz de Freitas
Embrapa Solos

Prof. Dr. Róberson Machado Pimentel
Universidade Federal Fluminense - UFF

Rio de Janeiro

2022

DEDICATÓRIA

Dedico esta tese de doutorado a Deus-Pai Todo-Poderoso (pois Ele é o autor da vida), aos meus pais (que me deram a vida), aos meus irmãos (que fazem parte da minha vida), aos meus sobrinhos e às crianças da catequese (que alegam a minha vida) e ao meu Jesus Cristo (que é a minha vida).

AGRADECIMENTOS

Agradeço a Deus-Pai Todo Poderoso que é o autor da vida e de toda a biodiversidade, do mundo em que vivemos, da natureza e do “meio ambiente”. Somos todos obras das Suas mãos.

Agradeço aos meus pais, Mateus Ferreira de Almeida e Virgínia Maria Alves Benchimol, que desde sempre cuidaram de mim e suportaram todas as minhas necessidades, eles foram os primeiros que acreditaram em mim quando mostrei-lhes o desejo de fazer o doutorado. Eles me incentivaram e me acompanharam para conhecermos a minha querida orientadora. A eles o meu muito obrigado. Eles sim são os meus Doutores por excelência, na minha vida. Fazê-los lembrar que esse triunfo é muito mais deles do que meu.

Agradeço à minha orientadora, Dra. Margareth Simões, que me acolheu, e como uma mãe soube me guiar pelos árduos caminhos da ciência, ela que sabiamente soube direcionar a pesquisa científica no melhor caminho, tendo sido uma grande incentivadora para o sucesso da presente tese de doutorado. Obrigado por tudo, e especialmente, pela paciência.

Agradeço ao meu coorientador, Dr. Rodrigo Peçanha Demonte Ferraz, que teve uma visão científica bastante holística, além de ser constantemente detalhista nas suas abordagens e questionamentos, o que contribuiu grandemente para o aprofundamento da presente pesquisa. Obrigado pelas conversas nos momentos de descontração.

Agradeço à Embrapa Solos, por ter me contratado como pesquisador visitante, abrindo as portas da empresa para que eu frequentasse o recinto, os laboratórios, permitindo o contato com o pessoal altamente capacitado e qualificado, o meu muito obrigado.

Agradeço à Universidade do Estado do Rio de Janeiro (UERJ), de modo especial, ao Programa de Pós-graduação em Meio Ambiente (PPGMA) por me permitir realizar esse sonho. Agradeço a todos os Professores do PPGMA que com alto nível de profissionalismo nos transmitiram os conteúdos tão valiosos das disciplinas, e muitas vezes mesmo sem salários se sacrificaram para o nosso bem; às secretárias Danielle e Jeniffer que com muita paciência sempre atenderam as nossas demandas. A todos o meu muito obrigado.

Agradeço ao Instituto Militar de Engenharia (IME), primeira universidade que me acolheu aqui no Brasil e me preparou para a realidade brasileira, e particularmente, ao curso de Mestrado em Engenharia Cartográfica e a todos os Professores, o meu muito obrigado.

Agradeço à Faculdade de Ciência da Universidade Agostinho Neto de Angola, particularmente, ao curso de Engenharia Geográfica, por ser a primeira universidade que

frequentei na minha vida, além de ser o primeiro marco de uma grande caminhada. Muito obrigado.

Agradeço aos meus irmãos, Jesus Benchimol Ferreira de Almeida e Leila Benchimol Ferreira de Almeida, à minha cunhada Rosa do Nascimento Mucavele de Almeida, ao meu cunhado Edgar António de Santana Pontes, aos meus sobrinhos (Edgar, Kaiser, Denzel, Keila, Kiria e Liliane) e a toda a minha família pela convivência, pelos momentos de lazer e descontração, por todas as brincadeiras, as mensagens e os vídeos no whatsapp e no facebook, pelas correntes de orações, pelos conselhos e por tudo, o meu muito obrigado.

Agradeço ao Padre Frank, ao Cônego Abílio, Padre Plácido, Padre Silvério, Padre Brito e Padre Igor que com as suas homilias têm me feito refletir mais a respeito da vida, e da relação entre Deus e os homens, procurando me aperfeiçoar a cada dia, o meu muito obrigado.

Agradeço à Igreja Santa Teresinha do Menino Jesus, ao Apostolado da Oração, à Pastoral dos Ministros da Eucaristia, à Pastoral do Meio Ambiente, à Catequese, ao Grupo Jovem e à Pastoral da Música, dos quais faço parte, estar com vocês tem sido muito relaxante, vocês têm sido um excelente refúgio para mim, o meu muito obrigado.

Agradeço aos meus amigos da igreja, Rafaella Diniz, Yasmin Marins Teixeira, Larissa Cabral, Rodolfo Beicht, Valéria Barbosa, Osvaldo Luís e aos demais.

Agradeço ao Governo de Angola, que por intermédio do Instituto Nacional de Bolsas de Estudo de Angola (INAGBE), concedeu-me uma bolsa de estudos para a realização do doutorado aqui no Brasil, o meu muito obrigado.

Agradeço a todos aqueles que de uma forma direta ou indireta contribuíram para a concretização deste trabalho, o meu muito obrigado.

Se tu podes crer; Tudo é possível ao que crê.

Marcos (9:23)

RESUMO

ALMEIDA, Mateus Benchimol Ferreira de. *Métodos de sensoriamento remoto orbital para o diagnóstico e monitoramento dos níveis de degradação de pastagens tropicais: uma contribuição ao plano de agricultura de baixa emissão de carbono*. 2022. 156f. Tese (Doutorado em Meio Ambiente) – Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2022.

A presente pesquisa científica objetivou avaliar diferentes métodos, índices de vegetação e texturas em contribuição ao desenvolvimento de uma metodologia de mapeamento e monitoramento dos diferentes níveis de degradação das pastagens, com base em técnicas de Sensoriamento Remoto e Processamento Digital de Imagens dos satélites Sentinel-2 e Sentinel-1, além de outros produtos satelitários. O estudo foi conduzido especificamente no município de Valença/RJ e arredores, no bioma da Mata Atlântica, onde foram obtidos pontos de campo georreferenciados com as suas respectivas classes atribuídas (N1, N2N3, N4), bem como na região do bioma Cerrado, onde os pontos de campo georreferenciados e os atributos associados foram obtidos por cortesia do LAPIG/MapBiomias. Este conjunto de dados foi classificado por um método de classificação supervisionada denominado *random forest*, que por sua vez, é um algoritmo de inteligência artificial e aprendizado de máquina que usa diferentes árvores de decisão para a rotulação dos pixels no processo de classificação. O processamento principal dos dados foi realizado no *Google Earth Engine*, porém o processamento auxiliar, que favoreceu sobremaneira o processamento principal, foi realizado no *R*. O índice de vegetação mais importante foi o NCI, no entanto, por si só, não garantiu uma acurácia satisfatória, sendo necessário adicionar outros produtos de sensoriamento remoto para este fim.

Também objetivou-se estimar as proporções dos elementos presentes na composição das pastagens nos seus diferentes níveis de degradação (N1, N2N3 e N4), com base na Análise de Mistura Espectral (AME) e nas imagens-fração VNFA (Vegetação Não Fotossinteticamente Ativa), VFA (Vegetação Fotossinteticamente Ativa), SE (Solo Exposto) e Sombra advindas da AME tanto para a época úmida quanto para a época seca. Com base nestas imagens-fração foi possível realizar mais uma vez a classificação *random forest* dos diferentes níveis de degradação das pastagens de todo o bioma Cerrado.

Para a estimativa das proporções VNFA, VFA, SE e Sombra foi necessário aplicar a Análise pró Componentes Principais (ACP) antes da AME com a finalidade de reduzir a correlação entre as bandas puras do Sentinel-2, ainda assim, só foi possível estimar as proporções na estação úmida.

Os resultados obtidos com base nas metodologias propostas e no controle estatístico dos dados (acurácias) permitem deduzir que ambas são robustas, eficientes e eficazes na separabilidade dos diferentes níveis de degradação das pastagens (N1, N2N3 e N4) tanto da Mata Atlântica (município de Valença/RJ e arredores) quanto do bioma Cerrado.

Palavras-chave: Sentinel-2. Sentinel-1. Índices de vegetação. NCI. Características biofísicas das pastagens (peso da biomassa, altura da biomassa e peso do material morto). Proporções dos componentes VNFA, VFA, SE e Sombra.

ABSTRACT

ALMEIDA, Mateus Benchimol Ferreira de. *Orbital remote sensing methods for diagnosing and monitoring of tropical pasture degradation levels: a contribution to the low carbon emission agricultural plan*. 2022. 156f. Tese (Doutorado em Meio Ambiente) – Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2022.

The present scientific research aimed to develop a methodology for mapping and monitoring the different pastures degradation levels (L1, L2L3 and L4) in the Atlantic Forest (specifically Valença/RJ municipality and surroundings) and in the Cerrado biome, based on techniques of Remote Sensing and Digital Image Processing from Sentinel-2 and Sentinel-1 satellites, in addition to other satellite products, as well as georeferenced field points with their respective assigned classes. This dataset was classified by a supervised classification method called random forest, which in turn is an artificial intelligence and machine learning algorithm that uses different decision trees for the labeling of pixels in the classification process. In addition, random forest in conjunction with Google Earth Engine is even more powerful, due to parallel computing and cloud computing provided by the Google Earth Engine platform. The main data processing was performed in Google Earth Engine, but the auxiliary processing, which greatly favored the main processing, was performed in R. The most important vegetation index was NCI, however, by itself, it didn't guarantee a satisfactory accuracy, being necessary to add other remote sensing products for this purpose.

The present scientific research also aimed to estimate the proportions of the elements present in the pastures composition at their different degradation levels (L1, L2L3 and L4), based on Spectral Mixture Analysis (SMA) and on NPV (Non-Photosynthetic Vegetation), PV (Photosynthetic Vegetation), BS (Bare Soil) and Shade fraction images from the SMA for both the wet and dry seasons. Based on these fractional images, it was possible to perform a random forest classification of the different pastures degradation levels in the Cerrado biome.

For estimation of NPV, PV, BS and Shadow proportions, it was necessary to apply the Principal Component Analysis (PCA) before the SMA in order to reduce the correlation among the pure bands of Sentinel-2, even so, it was only possible to estimate the proportions in the wet season.

The results obtained based on the proposed methodologies and on the statistical control of the data (accuracy) allow us to deduce that both are robust, efficient and effective in separating the different pastures degradation levels (L1, L2L3 and L4) both in the Atlantic Forest (Valença/RJ Municipality and surroundings) and the Cerrado biome.

Keywords: Sentinel-2. Sentinel-1. Vegetation indices. NCI. Pasture biophysical characteristics (green biomass weight, biomass height and dead biomass weight). Components proportions NPV, PV, BS and Shade.

LISTA DE FIGURAS

Figura 1 –	Ilustração simplificada do processo de degradação de pastagens.....	28
Figura 2 –	Árvore de decisão hipotética.....	35
Figura 3 –	Mapa de localização do bioma Mata Atlântica.....	38
Figura 4 –	Mapa de localização do bioma Cerrado.....	40
Figura 5 –	Dois (2) veículos da Embrapa Solos para apoio à equipe de campo..	41
Figura 6 –	Algumas das propriedades rurais percorridas e amostradas.....	42
Figura 7 –	Identificação das pastagens e das plantas invasoras.....	42
Figura 8 –	Pastagens sob pastejo.....	43
Figura 9 –	Níveis de degradação das pastagens.....	43
Figura 10 –	Coleta de amostras de pastagem ao longo de um transepto de 50 m com marcações aleatórias vermelhas e amarelas. O gabarito (quadrado de ferro) possui dimensões de 50 cm x 50 cm.....	44
Figura 11 –	Medição de altura das pastagens.....	45
Figura 12 –	Conservação das amostras de pastagem em freezer, processo de triagem, pesagem das amostras de pastagens separadas (50%) deposição de material na estufa de circulação forçada de ar.....	46
Figura 13 –	A equipe de campo.....	47
Figura 14 –	Níveis das pastagens degradadas.....	56
Figura 15 –	Pastagens sob pastejo.....	57
Figura 16 –	Mapa de localização, legenda e representação tridimensional.....	58
Figura 17 –	Fluxograma da metodologia proposta no <i>Google Earth Engine</i> (processamento principal).....	62
Figura 18 –	Processamento das 315 camadas (<i>layers</i>) no R.	68
Figura 19 –	Correlação entre alguns índices de vegetação ou texturas GLCM e características biofísicas das pastagens (biomassa, altura e material).....	70
Figura 20 –	Perfis temporais para a avaliação do comportamento das pastagens nos diferentes níveis de degradação (N1, N2N3 e N4).....	77

Figura 21 –	Informação do relevo em 3 regiões com diferentes níveis de degradação de pastagens.....	79
Figura 22 –	Mapa dos níveis de degradação de pastagens da área de estudo baseado em: S2 + IV** + Textura ₁₈ + VH+ Declividade.....	79
Figura 23 –	Estatísticas das áreas (ha) dos níveis de degradação de pastagens baseadas em: S2 + IV** + Textura ₁₈ + VH+ Declividade.....	80
Figura 24 –	Níveis das pastagens degradadas.....	87
Figura 25 –	Mapa de localização da área de estudo.....	89
Figura 26 –	Distribuição espacial dos 4.212 pontos de pastagens usados no presente estudos com a identificação dos seus respectivos níveis de degradação.....	90
Figura 27 –	Ciclo das chuvas do Cerrado: a) Período de março a agosto de 2019. b) Período de 2 anos (2018-2020).....	93
Figura 28 –	Fluxograma da metodologia proposta.....	94
Figura 29 –	Mapa dos níveis de degradação das pastagens do bioma Cerrado.....	96
Figura 30 –	Áreas de pastagens degradadas no nível N4 por estados do Cerrado.....	97
Figura 31 –	Áreas de pastagens degradadas no nível N2N3 por estados do Cerrado.....	98
Figura 32 –	Áreas de pastagens bem conservadas no nível N1 por estados do Cerrado.....	98
Figura 33 –	Áreas totais de pastagens por estados do Cerrado.....	99
Figura 34 –	Gráfico de áreas de pastagens totais do Cerrado.....	99
Figura 35 –	Relação do triângulo CAI-NDVI com os componentes puros (VNFA, VFA e SE) e misturados da imagem orbital.....	113
Figura 36 –	Níveis das pastagens degradadas.....	118
Figura 37 –	Mapa de localização da área de estudo (bioma Cerrado).....	119
Figura 38 –	Ciclo das chuvas do Cerrado.....	122
Figura 39 –	Composição de pastagem com a presença de material verde (VFA), material seco (VNFA), solo exposto (SE) e sombra (Sombra).....	124
Figura 40 –	Componentes puros da Análise de Mistura Espectral (AME).....	124

Figura 41 –	Distribuição espacial dos 4.212 pontos de pastagens usados no presente estudos com a identificação dos seus respectivos níveis de degradação.....	126
Figura 42 –	Fluxograma da metodologia proposta.....	127
Figura 43 –	Distanciamento entre pontos no interior de um pixel.....	128
Figura 44 –	Curvas do comportamento espectral dos componentes puros VNFA, VFA, SE e Sombra com base nas bandas espectrais selecionadas do Sentinel-2 (B2, B3, B4, B5, B6, B7, B8, B11 e B12).....	131
Figura 45 –	Correlação entre VNFA e SE com valores oriundos da AME.....	132
Figura 46 –	Correlação entre VNFA e SE com valores oriundos da ACP, e posteriormente, AME.....	132
Figura 47 –	Diagrama ternário dos níveis de degradação das pastagens do Cerrado baseado em frações de AME (modelo conceitual).....	133
Figura 48 –	Mapa dos níveis de degradação das pastagens do bioma Cerrado.....	135
Figura 49 –	Áreas de pastagens bem conservadas no nível N1 por estados do Cerrado.....	136
Figura 50 –	Áreas de pastagens degradadas no nível N2N3 por estados do Cerrado.....	136
Figura 51 –	Áreas de pastagens degradadas no nível N4 por estados do Cerrado.....	137
Figura 52 –	Áreas totais de pastagens por estados do Cerrado.....	138
Figura 53 –	Gráfico de áreas de pastagens totais do Cerrado.....	138

LISTA DE TABELAS

Tabela 1 –	Estádios de Degradação (ED) de pastagens segundo to Parâmetros Limitantes, indicadores de Queda na Capacidade de Suporte (QCS), e Nível de Degradação (Níveis).....	28
Tabela 2 –	Bandas espectrais MSI do Sentinel-2.....	31
Tabela 3 –	Informação das amostras de campo.....	57
Tabela 4 –	Informação das imagens Sentinel-2 utilizadas.....	59
Tabela 5 –	Índices de Vegetação para o Sentinel-2.....	64
Tabela 6 –	Testes de classificação supervisionada <i>random forest</i> e acurácias (AG e K) no R.....	67
Tabela 7 –	Teste de acurácia com diversos produtos de sensoriamento remoto..	74
Tabela 8 –	Controle da acurácia da classificação <i>random forest</i> com base em (S2 + IV** + Textura ₁₈ + VH+ Declividade).....	75
Tabela 9 –	Estádios de Degradação (ED) de pastagens segundo Parâmetros Limitantes, indicadores de Queda na Capacidade de Suporte (QCS), e Nível de Degradação (Nível).....	87
Tabela 10 –	Informação das amostras de campo.....	88
Tabela 11 –	Índices de Vegetação para o Sentinel-2.....	88
Tabela 12 –	Controle da acurácia da classificação <i>random forest</i>	97
Tabela 13 –	Estádios de Degradação (ED) de pastagens segundo Parâmetros Limitantes, indicadores de Queda na Capacidade de Suporte (QCS), e Nível de Degradação (Nível).....	117
Tabela 14 –	Informação das amostras de campo.....	118
Tabela 15 –	Controle da acurácia da classificação <i>random forest</i>	134

LISTA DE ABREVIATURAS E SIGLAS

ε_λ	Termo de erro
2D	Espaço bidimensional
ABC	Agricultura de Baixo Carbono
ACP	Análise por Componentes Principais
AG	Acurácia Geral
AHP	Análise multicritério
AM	Amazonas
AME	Análise de Mistura Espectral
AP	Amapá
AP	Amapá
APA	Área de Proteção Ambiental
AVIRIS	<i>Airbone Visible and Infrared Imaging Spectrometer</i>
B2	Banda azul
B3	Banda verde
B4	Banda vermelho
B5	Banda de borda vermelha
B6	Banda de borda vermelha
B7	Banda de borda vermelha
B8	Banda infravermelho próximo
B8A	Banda infravermelho próximo
B11	Banda infravermelho médio
B12	Banda infravermelho médio
BA	Bahia
BID	Banco Interamericano de Desenvolvimento
BS	<i>Bare Soil</i>
CAI	<i>Cellulose Absorption Index</i>
CCD	<i>Charge-coupled devices</i>
CH ₄	Metano
CHIRPS/PROBA	<i>Climate Hazards Group InfraRed Precipitation With Station Data</i>
CNA	Confederação da Agricultura e Pecuária do Brasil
CNRS	<i>Centre National de la Recherche Scientifique</i> (Centro Nacional de

	Pesquisa Científica)
CO ₂	Gás Carbônico
COP	<i>Conference of the Parties</i> (Conferência das Partes)
CRI1	<i>Carotenoid Reflectance Index 1</i>
CRI1	<i>Carotenoid Reflectance Index 1</i>
CRI2	<i>Carotenoid Reflectance Index 2</i>
CRI2	<i>Carotenoid Reflectance Index 2</i>
DF	Distrito Federal
DFI	<i>Dead Fuel Index</i>
DN	<i>Digital Number</i> (Número Digital)
DSG	Diretoria de Serviço Geográfico
ED	Estádios de Degradação
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
EMQ	Erro Médio Quadrático
EnMap	Programa de Mapeamento e Análise Ambiental
ESA	<i>European Space Agency</i> (Agência Espacial Europeia)
EVI	<i>Enhanced Vegetation Index</i>
EVI2	<i>Enhanced Vegetation Index</i>
EW	<i>Extra-Wide</i>
FAO	<i>Food and Agriculture Organization of the United Nations</i>
GEE	Gases de Efeito Estufa
GeoABC	Metodologias e inovações tecnológicas para o monitoramento e o planejamento da agricultura de baixa emissão de carbono em apoio à governança do plano ABC
GLCM	<i>Gray-Level Co-occurrence Matrices</i>
GO	Goiás
GPS	<i>Global Positioning System</i> (Sistema de Posicionamento Global)
GRD	<i>Ground Range Detected</i>
HH	Horizontal-Horizontal
HV	Horizontal-Vertical
IAF	Índice de Área Foliar
IBGE	Instituto Brasileiro de Geografia e Estatística
ICMBIO	Instituto Chico Mendes de Conservação da Biodiversidade

IFOV	<i>Instantaneous-Field-Of-View</i> (Campo de visada instântaneo)
iLPF	integração Lavoura-Pecuária-Floresta
IME	Instituto Militar de Engenharia
INPE	Instituto Nacional de Pesquisas Espaciais
IPCC	<i>Intergovernmental Panel on Climate Change</i>
IW	Interferometric Wide
K	Índice <i>Kappa</i>
LAPIG	Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás
MA	Maranhão
MAPA	Ministério da Agricultura, Pecuária e Abastecimento
MG	Minas Gerais
MGRS	<i>Military Grid Reference System</i>
MLME	Modelo Linear de Mistura Espectral
MODIS	<i>Moderate Resolution Imaging Spectrometer</i>
MS	Mato Grosso do Sul
MSAVI	<i>Modified Soil Adjusted Vegetation Index</i>
MSI	MultiSpectral Instrument
MT	Mato Grosso
N	Nitrogênio
N1	Nível 1 de Degradação das Pastagens
N2	Nível 2 de Degradação das Pastagens
N ₂ O	Óxido nitroso
N3	Nível 3 de Degradação das Pastagens
N4	Nível 4 de Degradação das Pastagens
NCI	<i>Normalized Canopy Index</i>
NDC	Contribuição Nacionalmente Determinada
NDI	<i>Normalized Difference Index</i> (Índice de Diferença Normalizada)
NDI5	<i>Normalized Difference Index 5</i>
NDI7	<i>Normalized Difference Index 7</i>
NDSVI	<i>Normalized Difference Senescent Vegetation Index</i>
NDTI	<i>Normalized Difference Tillage Index</i>
NDVI	<i>Normalized Difference Vegetation Index</i>

NDWI ou NDMI	<i>Normalized Difference Moisture or Water Index</i>
NH ₃	Amônia
NIR	<i>Near Infrared</i> (Infravermelho próximo)
NO ₃	Nitrato
NPV	<i>Non-Photosynthetic Vegetation</i>
OCN	<i>Ocean</i>
ODS	Objetivos de Desenvolvimento Sustentáveis
ONU	Organização das Nações Unidas
OOB	<i>out-of-bag</i>
PA	Pará
PCA	Principal Component Analysis
PI	Piauí
PR	Paraná
PV	<i>Photosynthetic Vegetation</i>
QCS	Queda na Capacidade de Suporte
REDD+	<i>Reducing Emissions from Deforestation and forest Degradation +</i>
REP	<i>Red Edge Position</i>
RGR	<i>Red-Green Ration</i>
RJ	Rio de Janeiro
RO	Rondônia
RR	Roraima
S2	Sentinel-2
SAR	<i>Synthetic Aperture Radar</i>
SATVI	<i>Soil Adjusted Total Vegetation Index</i>
SAVI	<i>Soil Adjusted Vegetation Index</i>
SE	Solo Exposto
SIG	Sistemas de Informação Geográfica
SLC	<i>Single Look Complex</i>
SM	<i>Stripmap</i>
SMA	<i>Spectral Mixture Analysis</i>
SP	São Paulo
SR	<i>Simple Ratio</i>
SRTM	<i>Shuttle Radar Topography Mission</i>

STI	<i>Soil Tillage Index</i>
SWIR	<i>Short-Wave Infrared</i> (Infravermelho médio)
TO	Tocantins
TVI	Triangular Vegetation Index
UERJ	Universidade do Estado do Rio de Janeiro
UFF	Universidade Federal Fluminense
UN	<i>United Nations</i>
USGS	<i>United States Geological Survey</i>
VFA	Vegetação Fotossinteticamente Ativa
VH	Vertical-Horizontal
VIgreen	Green Vegetation Index
VIIRS	<i>Visible Infrared Imaging Radiometer Suite</i>
VNFA	Vegetação Não Fotossinteticamente Ativa
VV	Vertical-Vertical
WV	<i>Wave</i>

SUMÁRIO

	INTRODUÇÃO GERAL	21
1	Fundamentação teórica	27
1.1	Degradação de pastagens.....	27
1.2	Sensoriamento Remoto.....	31
1.2.1	<u>Sentinel-2</u>	31
1.2.2	<u>Sentinel-1</u>	32
1.2.2.1	Speckle.....	33
1.2.2.2	Correção de terreno.....	33
1.2.3	<u>Classificador <i>random forest</i></u>	34
1.3	Áreas de estudo.....	35
1.3.1	<u>Características físico-geográficas e socioambientais das áreas de estudo</u>	36
1.3.1.1	Bioma Mata Atlântica.....	36
1.3.1.2	Bioma Cerrado.....	38
1.4	Trabalhos de campo nas áreas de estudo.....	40
1.4.1	<u>Trabalho de campo em Valença/RJ</u>	40
1.4.1.2	A equipe de campo e de pesquisa.....	46
1.4.2	<u>Pontos de campo coletados no bioma Cerrado</u>	47
2	Uma abordagem de sensoriamento remoto baseada em imagens Sentinel-2 e SAR Sentinel-1 para o mapeamento dos níveis de degradação de pastagens: estudo de caso no bioma Mata Atlântica, Brasil	49
2.1	Introdução.....	50
2.2	Revisão bibliográfica.....	53
2.2.1	<u>Trabalhos relacionados</u>	53
2.2.2	<u>Carotenoides</u>	54
2.3	Metodologia.....	56
2.3.1	<u>Área de estudo</u>	56
2.3.2	<u>Materiais</u>	58
2.3.3	<u>Métodos</u>	59
2.3.3.1	Índices de Vegetação.....	63
2.3.3.2	Texturas GLCM.....	65

2.4	Resultados e discussões.....	65
2.4.1	<u>Processamento digital de imagens no R (processamento auxiliar)</u>	66
2.4.2	<u>Correlação entre os índices de vegetação e as características biofísicas das pastagens</u>	69
2.4.3	<u>Processamento digital de imagens no <i>Google Earth Engine</i> (processamento principal)</u>	73
2.5	Conclusões.....	80
3	Avaliação dos níveis de degradação das pastagens do bioma Cerrado, Brasil. Uma abordagem de sensoriamento remoto usando séries temporais de imagens Sentinel-2, <i>random forest</i> e <i>Google Earth Engine</i>.....	83
3.1	Introdução.....	84
3.2	Metodologia.....	86
3.2.1	<u>Área de estudo</u>	86
3.2.2	<u>Materiais</u>	88
3.2.3	<u>Métodos</u>	91
3.3	Resultados e discussões.....	95
3.4	Conclusões.....	100
4	Análise de mistura espectral para a avaliação e monitoramento dos níveis de degradação de pastagens no bioma Cerrado, Brasil. Uma abordagem de sensoriamento remoto usando Sentinel-2 e <i>Google Earth Engine</i>.....	102
4.1	Introdução.....	103
4.2	Revisão bibliográfica	108
4.2.1	<u>Trabalhos relacionados</u>	108
4.3	Análise de Mistura Espectral (AME).....	114
4.4	Metodologia.....	117
4.4.1	<u>Área de estudo</u>	117
4.4.2	<u>Materiais</u>	118
4.4.3	<u>Métodos</u>	120
4.4.3.1	Multiplicação dos pontos de campo.....	120
4.4.3.2	Seleção das imagens, bandas espectrais e período de aquisição.....	120
4.4.3.3	Análise de Mistura Espectral (AME).....	122
4.5	Processamento Digital de Imagens no <i>Google Earth Engine</i>	124

4.6	Resultados e discussões.....	129
4.7	Conclusões.....	140
	CONCLUSÕES GERAIS.....	143
	REFERÊNCIAS.....	146

INTRODUÇÃO GERAL

Os objetivos do Plano ABC e ABC+ do Governo do Brasil estão em consonância com os Objetivos de Desenvolvimento Sustentáveis (ODS), isto é, ODS 2 (Fome Zero e Agricultura Sustentável) e o ODS 13 (Ação Contra a Mudança Global do Clima), visando incentivar ações sustentáveis e de baixa emissão de carbono, tais como: a recuperação de pastagens degradadas, a integração Lavoura-Pecuária-Floresta (iLPF), o sistema de plantio direto, a fixação biológica de nitrogênio, florestas plantadas e o tratamento de dejetos animais (MAPA, 2021a). O Plano ABC surgiu como demanda do compromisso assumido pelo Brasil na COP15, que teve lugar em Copenhague em 2009 (MAPA, 2012). O plano ABC surge devido a crescente preocupação mundial com as questões ambientais, especificamente, com o aquecimento global e com as mudanças climáticas nos anos vindouros (MAPA, 2012). O Brasil tem desenvolvido um papel de liderança nessa temática (MAPA, 2012). Desse modo, o Brasil assumiu o compromisso de até 2020 reduzir as emissões de gases de efeito de estufa (GEE) em até 36,1 % e 38,9%, correspondendo à 1 bilhão de toneladas de CO₂ (MAPA, 2012; ZIMMER, 2012), e a reduzir as emissões de gases de efeito estufa em até 37% e 43% em 2025 e 2030 respectivamente, tendo como base o ano de 2005. (Governo da República Federativa do Brasil, 2020, 2015). O combate ao aquecimento global está de mãos dadas com o crescimento econômico sustentável e o combate a pobreza (MAPA, 2012). O plano ABC é uma política pública que apresenta detalhadamente os caminhos que o Brasil pretende seguir para alcançar com sucesso as metas afirmadas no seu compromisso de redução dos GEE (MAPA, 2012). Os órgãos envolvidos são: A Casa Civil da Presidência da República, o Ministério da Agricultura, Abastecimento e Pecuária (MAPA), o Ministério do Desenvolvimento Agrário e a sociedade civil (MAPA, 2012). O presente estudo está inserido no projeto GeoABC (EMBRAPA, 2015) que atua na problemática abordada no Plano ABC (Plano Setorial de Mitigação e de Adaptação às Mudanças Climáticas Visando à Consolidação de uma Economia de Baixa Emissão de Carbono na Agricultura), e tem como objetivo avaliar métodos e técnicas inovadoras na área do Sensoriamento Remoto e integração de dados espaciais para o norteamento de sistemas de produção agrícola alinhados às políticas de baixa emissão de carbono na agricultura.

Com uma projeção de crescimento populacional global acentuado nos próximos anos, isto é, cerca de 8,5 bilhões de pessoas em 2030, 9,7 bilhões em 2050 e 10,9 bilhões em 2100 (ONU, 2019), segundo estimativas da FAO, a demanda mundial de alimentos de origem

animal aumentará nos próximos anos (FAO, 2021, 2009), existindo assim a grande preocupação de aumento de produção de alimentos a nível global.

As pastagens degradadas podem ser consideradas como um passivo agroambiental visto que, por um lado, constituem um grande empecilho no aumento da produtividade pecuária nacional, e, por outro, se relacionam com a questão do aumento ou mitigação das emissões de gases de efeito estufa (dióxido carbono, metano e óxido nitroso). Razão pela qual o fomento à recuperação das pastagens degradadas contempla tanto o setor produtivo quanto as questões ambientais. Para tal, é necessário saber onde estas pastagens estão localizadas e em que grau de degradação se encontram para que se possa intervir, principalmente nas áreas prioritárias, com técnicas de recuperação de pastagens, bem como a posterior reinserção nos sistemas de produção agropecuários.

Desta forma, o Sensoriamento Remoto se apresenta como ferramenta ideal para esta tarefa, considerando as grandes extensões superficiais terrestres que precisam ser mapeadas, o baixo custo de operação com equipes técnicas (custo-benefício), a disponibilidade de imagens de satélite, softwares e/ou plataformas de Processamento Digital de Imagens de baixo custo, a frequência com que estes dados são fornecidos, bem como a relativa facilidade de replicação de todo o processo. Deste modo, surge a proposta da presente tese de doutorado para o mapeamento e avaliação da qualidade das pastagens por meio de técnicas de Sensoriamento Remoto e Processamento Digital de Imagens de satélite Sentinel-2, Sentinel-1, além de outros produtos satelitários e dados de campo.

Motivação

Necessidade de avaliar e testar diferentes métodos de mapeamento dos níveis de degradação das pastagens e avançar nos estudos de Sensoriamento Remoto como subsídio a este fim.

Justificativa

Consiste em avaliar novas abordagens metodológicas baseadas na caracterização das pastagens degradadas a partir de técnicas de Sensoriamento Remoto, trazendo como inovação a aplicação de sensores orbitais mais recentes, como o Sentinel-2 (20m) e o Sentinel-1 (10m), com maior resolução espacial e novas bandas espectrais disponíveis, permitindo o cálculo de diferentes índices de vegetação em escala regional e a oportunidade de mapear com maior

detalhamento (resolução espacial) os diferentes níveis de degradação das pastagens. Ademais, a estimativa das proporções VNFA, VFA, SE e Sombra advindas da Análise de Mistura Espectral (AME) nos diferentes níveis de degradação das pastagens, uma outra perspectiva de abordagem do mesmo problema de degradação das pastagens, é bastante favorecida com o uso de imagens de satélite de maior resolução espacial, como o Sentinel-2. O Brasil tem a ambição de mapear com maior detalhamento e acurácia os níveis de degradação das pastagens, considerando o que isso representa para o país, sendo um forte aliado no alcance dos objetivos propostos pelo Plano ABC e ABC+, nas suas NDC para o alcance dos ODS, bem como no posicionamento do país no cenário internacional frente às mudanças climáticas, fator decisivo e obrigatório para o crescimento do país por meio de negociações com as grandes potências mundiais.

Hipótese

É possível desenvolver e aplicar uma metodologia de mapeamento, monitoramento e avaliação da qualidade das pastagens nos diferentes níveis de degradação, com base em Sensoriamento Remoto e sensores orbitais com maior resolução espacial e novas bandas espectrais, possibilitando melhorias no detalhamento do mapeamento.

Objetivo geral

Avaliar diferentes índices de vegetação, texturas, bandas espectrais e outros produtos advindos de Sensoriamento Remoto para o diagnóstico e o monitoramento dos níveis de degradação das pastagens.

Objetivos específicos

- Avaliar o processo de degradação de pastagens com base em técnicas de Sensoriamento Remoto usando índices de vegetação, texturas, bandas espectrais (puras) de imagens Sentinel-2 (20m), bem como o uso de imagens Sentinel-1 nas polarizações VH (10m) e VV (10m), com base em algoritmos de inteligência artificial e aprendizado de máquina, como o *random forest*.
- Avaliar o processo de degradação das pastagens por meio da Análise de Mistura Espectral (AME) de imagens orbitais Sentinel-2 (10m), com base nas

proporções de Vegetação Não Fotossinteticamente Ativa (VNFA), Vegetação Fotossinteticamente Ativa (VFA), Solo Exposto (SE) e Sombra nas regiões de pastagem.

- Realizar estudos de caso nos biomas Mata Atlântica (especificamente no município de Valença/RJ) e em todo o bioma Cerrado.

Procedimentos teórico-metodológicos específicos

(i) Obter imagens de Sensoriamento Remoto que cobrem a área de estudo (Sentinel-2 e Sentinel-1); (ii) Calcular e identificar os índices de vegetação, texturas e bandas espectrais mais importantes na avaliação da qualidade das pastagens (iii) Correlacionar os índices de vegetação mais importantes com os indicadores biofísicos (peso da pastagem, altura da pastagem e material seco) coletados em campo, para verificar e comprovar o grau de importância dos mesmos; (iv) Avaliar as pastagens degradadas por meio das proporções resultantes da Análise de Mistura Espectral (AME); (v) Analisar e avaliar os resultados da degradação das pastagens; (vi) Elaborar um mapa dos níveis de degradação das pastagens (N1, N2N3 e N4), viabilizando a aplicação do Sensoriamento Remoto na área de estudo, para o monitoramento da degradação de pastagens, bem como dos níveis de degradação.

Estrutura da tese

A presente tese está estruturada em quatro (4) capítulos. O Capítulo 1 é introdutório e consiste nos aspectos fundamentais e basilares que sustentam toda a temática abordada na presente pesquisa científica, tais como questões relacionadas ao processo de degradação das pastagens, a descrição das áreas de estudo (características gerais da Mata Atlântica, em especial o município de Valença/RJ, e características do bioma Cerrado), a realização dos trabalhos de campo, entre outros; bem como questões mais técnicas relacionadas ao Sensoriamento Remoto e Processamento Digital de Imagens, tais como a classificação supervisionada *random forest*, a descrição das características das imagens Sentinel-2 e Sentinel-1. Outros aspectos introdutórios ainda são abordados ao longo da tese e se encontram dissolvidos no interior dos capítulos 1, 2, 3 e 4, como o Plano ABC e ABC+, a integração Lavoura-Pecuária-Floresta (iLPF), a Análise de Mistura Espectral (AME), entre outros.

O capítulo 2 foi escrito em forma de artigo científico, possuindo o seu próprio resumo, introdução, metodologia, desenvolvimento e conclusões individuais. Neste capítulo faz-se uma análise exploratória de um grande conjunto de dados de entrada, tais como: séries temporais de imagens de satélite Sentinel-2; diversos índices de vegetação e texturas; séries temporais de imagens de satélite Sentinel-1; dados SRTM; e pontos de campo dos diferentes níveis de degradação de pastagens (N1, N2N3 e N4) georreferenciados e com as suas respectivas classes atribuídas. Este capítulo tem como área de estudo o bioma Mata Atlântica, especificamente no município de Valença/RJ e arredores.

O capítulo 3 também foi elaborado em forma de artigo científico, contendo o seu próprio resumo, introdução, metodologia, desenvolvimento e conclusões individuais. A metodologia proposta neste capítulo é uma forma mais simplificada da metodologia do capítulo anterior, porém aplicada nas áreas de pastagens de todo o bioma Cerrado. Considerando as grandes extensões superficiais do bioma Cerrado e as limitações de processamento impostas pelo *Google Earth Engine* para cada usuário de modo individual, logicamente, foi necessário a redução das séries temporais de imagens de satélite, a redução dos índices de vegetação e de outros produtos de sensoriamento remoto usados na versão original (capítulo 2). Contudo, a metodologia simplificada também se mostrou ser eficiente com base na validação por meio de controle estatístico (acurácia).

O capítulo 4 igualmente foi elaborado em forma de artigo científico, com o seu próprio resumo, introdução, metodologia, desenvolvimento e conclusões individuais. Porém aqui, a ideia foi olhar a questão das pastagens degradadas por um outro prisma (perspectiva), em que as perguntas levantadas nos levaram a uma outra abordagem metodológica bastante diferenciada das metodologias propostas nos capítulos 2 e 3. Olhando atentamente para uma área de pastagens, tendo em conta o nível de degradação, observamos principalmente material verde (pastagem sadia), material seco (pastagem morta), sombra e solo exposto. A pergunta científica levantada neste capítulo consistiu em saber se seria possível estimar as proporções destas componentes por níveis de degradação de pastagens com base em imagens de satélite e técnicas de Sensoriamento Remoto e Processamento Digital de Imagens. Assim, chegamos à Análise de Mistura Espectral (AME), também conhecido como Modelo Linear de Mistura Espectral (MLME), que foi aplicada nas áreas de pastagens de todo o bioma Cerrado. No entanto, diferentemente da metodologia dos capítulos anteriores em que se usam séries temporais, neste capítulo o cenário é considerado como se fosse um retrato, na verdade dois retratos, um na época úmida e outro na época seca. Para a estimativa das proporções dos componentes das pastagens na época úmida tivemos algum sucesso, porém com certas

limitações, já para a época seca não foi possível realizar a estimativa das proporções com sucesso. Porém, com base nas imagens-fração obtidas pela aplicação da AME foi possível gerar um mapa de classificação das pastagens degradadas do bioma Cerrado, no entanto, em termos de acurácia, não superou a abordagem das séries temporais, o que infere que as metodologias proposta relativamente às séries temporais e índices de vegetação (capítulos 2 e 3) são mais robustas e eficientes, neste estudo, do que a metodologia proposta com base na AME (capítulo 4).


1 FUNDAMENTAÇÃO TEÓRICA

1.1 Degradação de pastagens

A degradação de pastagem é um processo evolutivo da perda do vigor, de produtividade, da capacidade de recuperação natural das pastagens para sustentar os níveis de produção e a qualidade exigida pelos animais, bem como o de superar os efeitos nocivos de pragas, doenças e invasoras, culminando com a degradação avançada dos recursos naturais em razão de manejos inadequados (MACEDO; ZIMMER, 1993). A principal causa antrópica direta que influencia no processo de degradação de pastagens é o manejo inadequado, principalmente, o constante uso de taxas de lotação que estejam além da capacidade de recuperação do pasto, devido o pastejo e o pisoteio (FAO, 2009).

A degradação de pastagens pode ser observada sob duas perspectivas, isto é, a degradação agrícola e a degradação biológica. A degradação agrícola consiste na mudança da composição botânica da pastagem, devido o surgimento de plantas daninhas (especialmente as dicotiledôneas) e da posterior redução da taxa de forragem (como o capim e leguminosas forrageiras), sendo exemplos dessa categoria de degradação, pastagens que perderam o vigor devido o ataque de insetos-praga (como a cigarrinha-das-pastagens) ou pastagens atacadas pela síndrome da morte do capim-marandu (DIAS-FILHO, 2015). Numa abordagem ecológica, essa degradação consistiria numa evolução do processo de sucessão secundária (DIAS-FILHO, 2004). Na degradação agrícola não há necessariamente a perda da capacidade do solo em suportar a biomassa vegetal, podendo até em alguns casos aumentar a biomassa das espécies invasoras em detrimento da biomassa forrageira cultivada (DIAS-FILHO, 2015). A causa da degradação agrícola é a competição entre o capim e as plantas daninhas herbáceas e lenhosas mais adaptadas ao ecossistema, reduzindo assim a capacidade de suporte das pastagens (DIAS-FILHO, 2015). Já a degradação biológica consiste na drástica diminuição da biomassa vegetal, que tem a sua origem na degradação do solo, devido a perda da capacidade de sustentar produção vegetal significativa, com base em condições de natureza química (perda de nutrientes e acidificação), física (erosão e compactação), biológica (perda de matéria orgânica) ou climática (estiagem excessiva) (DIAS-FILHO, 2015).

Figura 1– Ilustração simplificada do processo de degradação de pastagens.



Fonte:DIAS-FILHO, 2015.

Os estádios de degradação de pastagens estão classificados conforme a Tabela 1. A degradação de pastagens se agrava do estágio ED1 ao estágio ED4. A pastagem no estágio ED4 pode ser uma fonte de propagação de calor (infravermelho) na atmosfera, devido o solo descoberto, contribuindo ainda para o aquecimento global (PRIMAVESI; ARZABE; DOS SANTOS PEREIRA, 2007). A queda da capacidade de suporte (QCS) é estimada com base nos seguintes pressupostos: considera-se que a capacidade de suporte plena (100%) é alcançada caso a cobertura de solo pela forrageira for de 100% ou próxima a esse valor.

Tabela 1 – Estádios de Degradação (ED) de pastagens segundo to Parâmetros Limitantes, indicadores de Queda na Capacidade de Suporte (QCS), e Nível de Degradação (Níveis).

ED	Parâmetro Limitante	QCS (%)	Nível
1	Vigor e solo descoberto	Até 20	Leve (N1)
2	Estádio 1 agravado + plantas invasoras	21 - 50	Moderado (N2)
3	Estádio 2 agravado ou morte das forrageiras (degradação agrícola)	51 - 80	Forte (N3)
4	Solo descoberto + erosão (degradação biológica)	> 80	Muito forte (N4)

Fonte: Adaptado de DIAS-FILHO, 2015.

O capim-marandu (*Brachiaria Brizantha* (A. Rich.)) possui grande representatividade nas pastagens do Brasil, estando estimado em 60 milhões de hectares, sendo que uma das principais causas de degradação de pastagens é a síndrome da morte do capim-marandu (MARCHI et al., 2006). No Brasil, essa síndrome surgiu nos meados dos anos 1990 no Acre, Pará e Rondônia, porém em 1998 a Amazônia Legal já possuía extensas regiões de pastagens

afetadas pela síndrome (NETO et al., 2000; VALENTIM; AMARAL, E; MELO, 2000). A síndrome da morte do capim-marandu ocorre na época chuvosa, em regiões com solos de baixa permeabilidade provocando encharcamento e posterior ataque de fungos ao capim-marandu, já sendo a principal causa de degradação no Acre (ARAÚJO, 2011; MARCHI et al., 2006).

As plantas utilizam moléculas de nitrogênio na forma de nitratos (NO_3) e amônia (NH_3) para a produção da própria matéria orgânica (CHRISTOPHERSON, 2012). O nitrogênio é um dos elementos mais necessários ao desenvolvimento das plantas, estando em falta, é também um componente limitante do crescimento das pastagens face a um manejo inadequado (BODDEY et al., 2004). Devido o esgotamento da fertilidade natural do solo, os pecuaristas têm realizado uma substituição cíclica de forragens por outras menos exigentes, e normalmente, menos nutritivas (FILHO; MONTEIRO; CORSI, 1992). Assim, uma das principais causas de degradação de pastagens é a deficiência de nitrogênio (N) no solo (WERNER, 1986). A fertilização e o manejo são práticas necessárias para a longevidade e produtividade das pastagens (FILHO; MONTEIRO; CORSI, 1992). Sendo que no Estado de Roraima, essa é a principal causa de degradação das pastagens cultivadas (DIAS-FILHO; ANDRADE, 2006). Segundo estimativas, aproximadamente metade da área de pastagens cultivadas na Amazônia Brasileira está degradada ou em estágio avançado de degradação (SERRÃO; UHL; NEPSTAD, 1993).

No Brasil, a pecuária teve um grande impulso na década de 60, devido a estratégia governamental da ocupação rápida do país (BRAZ et al., 2004). Assim, para a ocupação de grandes extensões de terras utilizou-se como meio a formação de pastagens, que por sua vez, é uma solução rápida e barata (BRAZ et al., 2004). Desse modo, a vegetação nativa passou a ser substituída pelas pastagens com a retirada de madeira de alto valor comercial e queimando-se o material restante para permitir a mecanização dos solos e a introdução de gramíneas forrageiras (BRAZ et al., 2004). Apesar da baixa fertilidade natural dos solos sob as pastagens (latossolos e areias quartzosas), a queima da vegetação nativa fornecia momentaneamente nutrientes ao solo proporcionando alto potencial produtivo de pastagens (BRAZ et al., 2004). Devido o superpastejo das pastagens no seu período de menor crescimento, observava-se a queda da produtividade incentivando a ocupação de novas áreas de vegetação nativa com pastagens, agravando ainda mais o desmatamento (BRAZ et al., 2004) e provocando perda de biodiversidade e modificação dos ecossistemas (VEIGA et al., 2000). Por esse motivo, as pastagens têm sido alvo de críticas pesadas pelos ambientalistas (VEIGA et al., 2000). Segundo dados do INPE, na Amazônia Brasileira já foram derrubados

no Bioma Amazônia 729.781,76 km², e na Amazônia Legal 813.063,44 km² de floresta nativa (INPE, 2021).

Normalmente, a degradação de pastagens deve-se à fertilidade do solo, à pressão biótica (pragas, doenças e plantas invasoras), ao estabelecimento (preparo da área e qualidade da semente) e ao manejo do pastejo (VEIGA et al., 2000).

No Brasil, a criação de gado bovino de corte e de leite é realizada principalmente em pastagens (MACEDO, 2009). A integração lavoura-pecuária possibilita a intensificação e o melhoramento do uso da terra, favorecendo maior produção, em tempo e área menores, além da redução das taxas de emissão de gases de efeito estufa por unidade de alimento produzido (MACEDO, 2009). A perda da capacidade de suporte animal ao longo do tempo é considerada como uma das características que melhor caracteriza o processo de degradação das pastagens (ZIMMER et al., 2012).

Os Gases de Efeito Estufa (GEE) emitidos na atmosfera devido a prática da pecuária são: o metano (CH₄), o óxido nitroso (N₂O) e o gás carbônico (CO₂) (CERRI et al., 2009). O metano está vinculado principalmente ao processo de fermentação do alimento no rúmen (KELLIHER; CLARK, 2010). O N₂O está relacionado com os processos químicos que ocorrem no contato entre a urina do gado e o solo (especialmente solos compactados e encharcados), além das adubações nitrogenadas e calagens (LUO et al., 2010). O CO₂ é mais intenso em práticas de manejo que resultem na redução da matéria orgânica do solo e da biomassa da pastagem (queima, revolvimento do solo, sobrepastejo, entre outros) (JONES; DONNELLY, 2004).

Apesar da pecuária constituir uma potencial fonte de GEE, esta pode se tornar também um forte potencial na redução dos GEE, especialmente, se praticada a pasto, isso deve-se ao sequestro de CO₂ da atmosfera para o solo (GERBER et al., 2010; MAIA et al., 2009; SOUSSANA; TALLEC; BLANFORT, 2010), sendo que em pastos recuperados, com maior produtividade de pastagens pode-se mitigar as emissões de gases de efeito estufa por animal (DIAS-FILHO, 2014).

As pastagens degradadas possuem forragens de baixa qualidade, isto é, menor digestibilidade e valor proteico, levando a menores taxas de passagem no rúmen, provocando assim a uma maior emissão de CH₄ na atmosfera por unidade de matéria seca consumida pelo gado (ECKARD; GRAINGER; DE KLEIN, 2010; PRIMAVESI et al., 2004). Os solos compactados e o aumento da população de cupins são fenômenos vinculados à degradação de pastagens podem favorecer respectivamente a emissão de N₂O (devido os encharcamentos) e de CH₄ (DIAS-FILHO, 2015).

1.2 Sensoriamento Remoto

1.2.1 Sentinel-2

A missão Sentinel-2 pertence ao programa Copernicus da ESA (ESA, 2022a; EUROPEAN SPACE AGENCY, 2022a). A constelação Sentinel-2 é constituída pelos satélites Sentinel-2A e Sentinel-2B, ambos são satélites similares (LILLESAND; KIEFER; CHIPMAN, 2015). O Sentinel-2A foi lançado em 23 de Junho de 2015, já o Sentinel-2B foi lançado em 7 de março de 2017 (ESA, 2022a). As imagens fornecidas pelo sensor MSI do Sentinel-2 possuem uma resolução radiométrica de 12-bit, isto é, 2^{12} , ou seja, 4.096 possíveis valores de nível de cinza, podendo os pixels assumirem valores no intervalo [0, 4.095] (ESA, 2022b). Quanto à resolução temporal os satélites Sentinel-2A e 2B têm um período de revisita de 5 dias (ESA, 2022c; LILLESAND; KIEFER; CHIPMAN, 2015). A resolução espacial do Sentinel-2 pode ser de 10m, 20m ou 60m de acordo a banda espectral em questão (ESA, 2022d), conforme Tabela 2. Quanto à resolução espectral, na Tabela 2 apresentam-se as características das bandas espectrais do Sentinel-2.

Tabela 2 – Bandas espectrais MSI do Sentinel-2

Banda	Localização no espectro	Centro (μm)	Largura da banda (μm)	Descrição ou uso	Resolução espacial (m)
1	Visível	0.433	0.020	Azul [Correção de aerossol]	60
2*	Visível	0.490	0.065	Azul [Correção de aerossol]	10
3*	Visível	0.560	0.035	Verde	10
4*	Visível	0.665	0.030	Vermelho	10
5*	NIR	0.705	0.015	<i>Red Edge</i>	20
6*	NIR	0.740	0.015	<i>Red Edge</i>	20
7*	NIR	0.775	0.020	<i>Red Edge</i>	20
8*	NIR	0.842	0.115	[Correção de vapor de água]	10
8A*	NIR	0.865	0.020	[Correção de vapor de água]	20
9	NIR	0.940	0.020	[Correção de vapor de água]	60
10	SWIR	1.375	0.030	[Detecção de cirrus]	60
11*	SWIR	1.610	0.090	Neve/Gelo/Nuvem	20
12*	SWIR	2.190	0.180	Neve/Gelo/Nuvem e [Correção de aerossol]	20

Legenda: * Indica bandas que contribuem primariamente para trabalhos que objetivam a classificação do uso e cobertura da Terra, avaliação das condições da vegetação, diferenciação de neve/gelo/nuvem, e discriminação mineral. [] Indica bandas usadas unicamente ou secundariamente para calibração ou correção.

Fonte: (EUROPEAN SPACE AGENCY, 2022a; GOOGLE EARTH ENGINE, 2022a; LILLESAND; KIEFER; CHIPMAN, 2015).

1.2.2 Sentinel-1

A missão Sentinel-1 da ESA corresponde a uma constelação de dois satélites SAR C-band, i.e., o Sentinel-1A e o Sentinel-1B. O Sentinel-1A foi lançado em 03 abril 2014, já o Sentinel-1B foi lançado em 25 abril 2016, além disso, também está programado para 2023 o lançamento do Sentinel-1C (ESA, 2022e).

As imagens Sentinel-1 podem ser disponibilizadas nos modos Interferometric Wide swath (IW), Extra-Wide swath (EW), Wave (WV) e Stripmap (SM). Sendo que as imagens nos modos IW, SM e EW são disponibilizadas nas polarizações HH, VV, HH+HV e VV+VH. Já as imagens no modo WV são apenas disponibilizadas nas polarizações HH ou VV. As imagens Sentinel-1 podem ser fornecidas nos seguintes níveis de pré-processamento: Level-0, Level-1 SLC (*Single Look Complex*), Level-1 GRD (*Ground Range Detected*) e Level-2 OCN (*Ocean*) (ESA, 2022f, 2022g).

O modo IW tem a finalidade de imagear a superfície terrestre; o modo WV captura imagens do oceano aberto; o modo EW coleta imagens zona costeira, podendo monitorar navios, monitoramento de gelo marinho e derramamento de óleo no mar; e o modo SM é destino a imagear pequenas ilhas e desastres naturais (ESA, 2022g).

Todas as imagens disponibilizadas no *Google Earth Engine* no formato GRD já são pré-processadas com o *Sentinel-1 Toolbox* (ferramenta desenvolvida pela ESA) nas seguintes etapas:

- Remoção de ruído térmico;
- Calibração radiométrica;
- Ortorretificação com base no SRTM (30m) ou o ASTER DEM para regiões acima de 60° de latitude N ou S, onde o SRTM não está disponível. Os valores da ortorretificação correspondem a conversão do sinal do radar em decibéis com base na fórmula $(10 \cdot \log_{10}(x))$ (GOOGLE EARTH ENGINE, 2022b).

As imagens Sentinel-1 no *Google Earth Engine* podem já ser disponibilizadas no formato *Ground Range Detected* (GRD), isto é, já são corrigidas das distorções advindas da geometria do imageamento de radar; na banda C (comprimento de onda de 6 cm); nas polarizações VV (co-polarização em banda única, transmissão vertical/recepção horizontal), HH (co-polarização em banda única, transmissão horizontal, recepção horizontal), VV + VH (polarização cruzada em banda dupla, transmissão vertical/recepção horizontal) e HH + HV

(polarização cruzada em banda dupla, transmissão horizontal/recepção vertical); e com tamanho de pixel de 10m, 25m e 40m (GOOGLE EARTH ENGINE, 2022b).

1.2.2.1 Speckle

O speckle é um ruído impulsivo que ocorre nas imagens de radar, gerando valores saturados iguais aos valores mínimos e máximos permitidos na imagem digitalizada, representados por áreas claras e escuras distribuídas aleatoriamente na imagem (GONZALEZ; WOODS, 2010; LILLESAND; KIEFER; CHIPMAN, 2015; MATHER; KOCH, 2011). É caracterizado por um padrão granulado do tipo sal e pimenta, devido à natureza coerente das micro-ondas, causando uma interferência aleatória construtiva e destrutiva (JENSEN, 2011). Os pulsos de radar são transmitidos de forma coerente, de modo que as ondas oscilam em fase. Quando há combinação de fases o sinal é amplificado e ocorre a interferência construtiva, quando as fases são opostas ocorre a interferência destrutiva (LILLESAND; KIEFER; CHIPMAN, 2015). O ruído speckle pode ser reduzido através do processamento de múltiplos “looks”, que consiste no processamento de porções de uma imagem e recombinação dessas porções, de forma que a interferência não ocorra (JENSEN, 2011; LILLESAND; KIEFER; CHIPMAN, 2015). Esse processamento produz uma melhoria visual na imagem, porém degrada a resolução da imagem (JENSEN, 2011; LILLESAND; KIEFER; CHIPMAN, 2015). Existem alguns filtros que permitem a redução do ruído speckle, como o filtro de Lee (LEE, 1981), filtro de Frost, o filtro Gaussiano, o filtro de média, entre outros (CHOI; JEONG, 2019; MATHER; KOCH, 2011)

1.2.2.2 Correção de terreno

As imagens de radar são bastante afetadas pelo relevo. Assim, realizar a correção dos efeitos do relevo, também conhecida como correção geométrica ou ortorretificação, é de grande importância para a extração de detalhes planimétricos, distâncias precisas, áreas ou direções (JENSEN, 2011, 2016; LONGLEY et al., 2013; MENEZES; FERNANDES, 2013).

Para tal é necessário o auxílio de um modelo digital de elevação, como por exemplo, o Shuttle Radar Topography Mission (SRTM) (GOOGLE EARTH ENGINE, 2022b).

1.2.3 Classificador *random forest*

O *random forest* (floresta aleatória) é um algoritmo de aprendizagem de máquina (*machine learning*) que utiliza múltiplas árvores de decisão (*ensemble*) simultaneamente, porém treinadas individualmente por meio de subconjuntos de dados, para efetuar a tarefa de classificação supervisionada de imagens digitais (BREIMAN, 2001; JENSEN, 2016; ZANOTTA; FERREIRA; ZORTEA, 2019).

Para um dado pixel não classificado, cada uma das árvores de decisão classifica este pixel, com base no seu atributo, numa das possíveis classes indicadas pelo operador durante o treinamento. Deste modo, o *random forest* rotula o pixel com a classe mais votada pelas árvores de decisão (BREIMAN, 2001; BREIMAN; CUTLER, 2014; JENSEN, 2016).

As árvores de decisão crescem com base no conjunto de dados de treinamento, em que utilizam o número de casos deste conjunto para selecionar aleatoriamente a mesma quantidade nos dados originais, porém, este subconjunto de dados vai sendo substituído ao longo do treinamento das árvores de decisão (JENSEN, 2016). Cada árvore de decisão utiliza apenas cerca de 70% dos dados de treinamento, os demais 30% são deixados de fora “out-of-bag (OOB)”, sendo posteriormente utilizados na estimativa da acurácia da classificação, o que pode ser bastante útil principalmente quando não se tem dados para a validação (JENSEN, 2016; ZANOTTA; FERREIRA; ZORTEA, 2019).

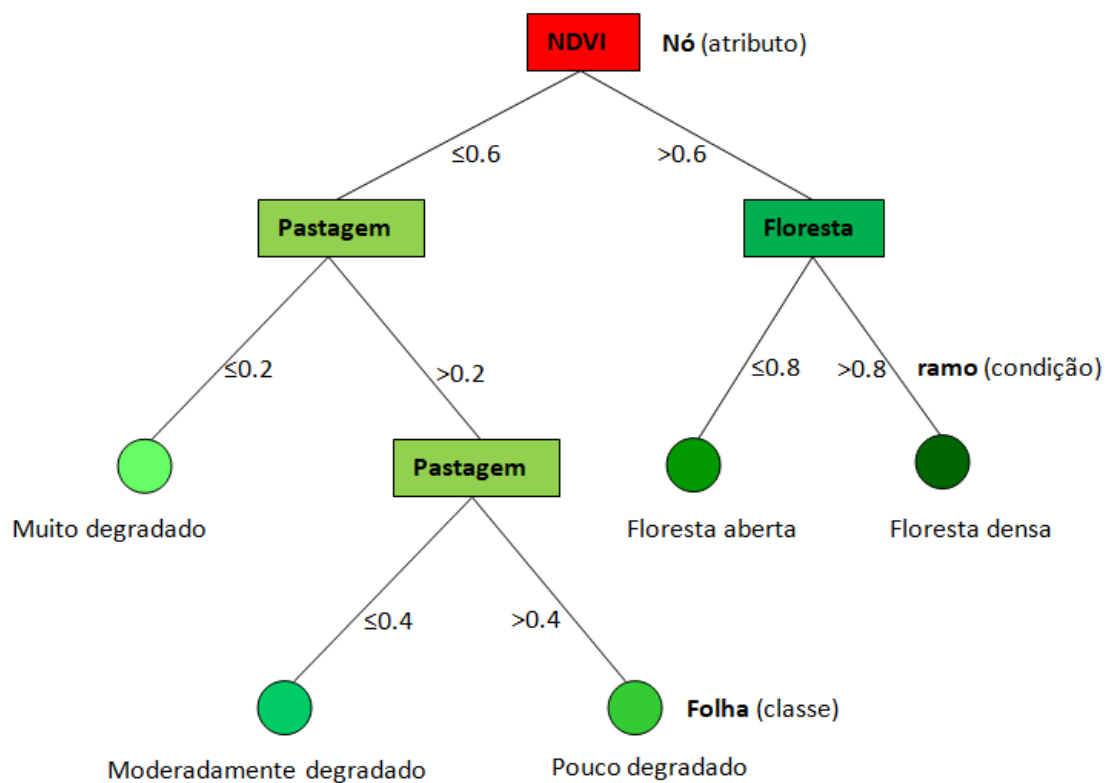
Uma das características mais interessantes do *random forest* é que este algoritmo de classificação supervisionada de imagens fornece informações sobre as variáveis (bandas espectrais, índices de vegetação, etc.) mais importantes no processo de classificação.

Considerando um conjunto de variáveis de entrada (bandas espectrais, índices de vegetação, etc.), recomenda-se que o número de variáveis aleatórias selecionadas por cada nó seja a raiz quadrada do número de variáveis de entrada; as árvores de decisão do *random forest* crescem o máximo possível, sem critério de poda. (JENSEN, 2016).

Este algoritmo é robusto mesmo com a ocorrência de outliers e ruídos, suporta volumosos conjuntos de dados para processamento, apresenta bom desempenho computacional e rápido processamento (BREIMAN, 2001; MATHER; KOCH, 2011).

Na Figura 2 apresenta-se a ilustração de uma árvore de decisão hipotética, em que a mesma é constituída por nós, ramos e folhas. A estrutura da árvore de decisão lembra a estrutura de uma árvore real invertida, com as raízes para cima e as folhas para baixo. Desta forma, o primeiro nó é denominado nó raiz, e os demais nós são denominados nós internos. Em cada nó existe um atributo que pode ser uma banda espectral, um índice de vegetação, uma textura, entre outros. Os ramos representam as condições estabelecidas aos atributos existentes nos nós. Cada percurso da raiz à folha define uma regra de classificação. E as folhas representam as classes. Existem várias formas de representar uma árvore de decisão.

Figura 2 – Árvore de decisão hipotética.



Fonte: O autor.

1.3 Áreas de estudo

As áreas de estudo seleccionadas na presente pesquisa correspondem:

1 – Valença/RJ (bioma Mata Atlântica): Consiste em uma região de pastagens cultivadas nos arredores da Fazenda Santa Mônica, correspondente a uma região da bacia leiteira, localizada no Vale do Rio Paraíba do Sul, no município de Valença, no Estado do Rio de Janeiro (RJ). Essa região corresponde à área de calibração e validação do método proposto na presente pesquisa, e foi selecionada com base nos critérios de relevância da região de pecuária, tais como: notória ocorrência de processos de degradação e perda de produtividade das pastagens, apoio e parcerias de campo e a disponibilidade de dados. A área de estudo se localiza no médio curso do rio Paraíba do Sul no Estado do Rio de Janeiro, cujo ciclo agroeconômico do café no século XII, deixou um legado de áreas exauridas que evoluíram para pastagens, hoje em sua maioria, bastante degradadas, a despeito da sua importância como bacia leiteira da Região Sudeste do país. Nesta área encontra-se a Fazenda de Santa Mônica (Fazenda Experimental da Embrapa) situada no distrito Barão de Juparanã, no município de Valença (RJ) na qual já se encontra instalado um experimento de campo para a calibração das pastagens na respectiva área de estudo.

2 – Bioma Cerrado: É responsável pela maior produção agropecuária do Brasil, contribuindo com 55% da produção de carne do país (EMBRAPA, 2014a). Até o ano de 2020, o Cerrado possuía uma área de pastagens de cerca de 48.160.607 ha (MAPBIOMAS, 2021). Segundo um estudo da Embrapa, mais de metade das pastagens do Cerrado podem se encontrar em algum estágio de degradação (EMBRAPA, 2014a). O mesmo estudo indica que a recuperação das pastagens poderia triplicar a produção de carne no Cerrado ou promover a expansão da agricultura, além de mitigar as emissões de gases de efeito estufa (EMBRAPA, 2014a). Por este motivo selecionou-se o Cerrado como área de estudo.

1.3.1 Características físico-geográficas e socioambientais das áreas de estudo

1.3.1.1 Bioma Mata Atlântica

A Mata Atlântica é um dos 6 biomas brasileiros, ocupando cerca de 15% do território nacional e abrangendo 17 estados: Alagoas, Bahia, Ceará, Espírito Santo, Goiás, Mato Grosso do Sul, Minas Gerais, Paraíba, Paraná, Pernambuco, Piauí, Rio de Janeiro, Rio Grande do Norte, Rio Grande do Sul, Santa Catarina, São Paulo e Sergipe (INPE, 2017). A Mata


Atlântica é o bioma brasileiro mais devastado e está entre os cinco “hotspot” de biodiversidade mais críticos da Terra, devido a sua fragmentação e devastação que vem decorrendo ao longo da história (BIOTA DE ORTHOPTERA DO BRASIL, 2022a; RBMA, 2022). A composição vegetal deste bioma consiste em formações florestais nativas como Floresta Ombrófila Densa, Floresta Ombrófila Mista ou Mata de Araucárias, Floresta Ombrófila Aberta, Floresta Estacional Semidecidual e Floresta Estacional Decidual; além de ecossistemas associados como vegetações de restingas, encaves de florestas do Nordeste, campos de altitude, manguezais e brejos interioranos (MMA, 2022). Atualmente restam apenas 16,2 milhões de hectares, isto é, 12,4% da área original do bioma (INPE, 2017).

Estima-se que a Mata Atlântica alberga cerca de 270 espécies de mamíferos, 850 espécies de aves, 200 espécies de répteis, 370 espécies de anfíbios e 850 espécies de aves, além de 20.000 espécies vegetais, ou seja, 35% das espécies vegetais do país, tendo em conta que muitas destas espécies são endêmicas e ameaçadas de extinção, sendo uma das florestas mais ricas em biodiversidade da Terra (MMA, 2022; RBMA, 2022).

Este bioma possui um clima predominantemente tropical úmido, com temperaturas médias elevadas por todo o ano (BIOTA DE ORTHOPTERA DO BRASIL, 2022a). Em relação as chuvas, o bioma possui precipitações pluviométricas regulares e bem distribuídas (BIOTA DE ORTHOPTERA DO BRASIL, 2022a). Planaltos e serras são características importantes do relevo deste bioma (BIOTA DE ORTHOPTERA DO BRASIL, 2022a). Quanto à hidrografia, o bioma é privilegiado, pois alberga algumas das mais importantes bacias hidrográficas do Brasil, isto é, a bacia do rio Doce, bacia do rio Paraíba do Sul, bacia do Paraná, bacia do rio Jequitinhonha, bacia do Uruguai e bacia do rio São Francisco (BIOTA DE ORTHOPTERA DO BRASIL, 2022a).

A Mata Atlântica abriga cerca de 72% da população brasileira (cerca de 145 milhões de habitantes) responsável por mais de 70% da economia do país, favorecendo-a com serviços ecossistêmicos tais como: disponibilização de água potável, produção de alimentos, remédios, regulação e equilíbrio climático, fertilidade e proteção do solo, proteção das encostas e mitigação de desastres, disponibilidade de madeira e outras matérias-primas (INPE, 2017; MMA, 2022; RBMA, 2022). Além disso, torna possível atividades fundamentais como agricultura, pecuária, pesca, produção de energia, turismo, lazer, entre outras (INPE, 2017).

Figura 3 – Mapa de localização do bioma Mata Atlântica.



Fonte: O autor.

1.3.1.2 Bioma Cerrado

O bioma Cerrado é segundo maior bioma do Brasil, localizado principalmente no Planalto Central Brasileiro, ocupando cerca de 24% do território nacional, compreendendo a uma área superficial de 2.036.448 km² e abrangendo os estados da Bahia (BA;), Distrito Federal (DF), Goiás (GO), Maranhão (MA), Mato Grosso (MT), Mato Grosso do Sul (MS), Minas Gerais (MG), Paraná (PR), Piauí (PI), Rondônia (RO), São Paulo (SP), Tocantins (TO), além de áreas disjuntas de Cerrado nos estados do Amapá (AP), Amazonas (AM), Pará (PA) e Roraima (RR), (EMBRAPA, 2022; IBGE, 2022a, 2022b; ICMBIO, 2022).

Este bioma possui uma vegetação que entremeia formações campestres (campo limpo) e formações florestais (cerradão) (BIOTA DE ORTHOPTERA DO BRASIL, 2022b). Em boa parte de sua extensão, o cerrado é bastante semelhante a savana, com ocorrência de

gramíneas, arbustos e árvores esparsas (BIOTA DE ORTHOPTERA DO BRASIL, 2022b). Comparativamente às demais savanas, o Cerrado predomina relativamente à diversidade, albergando cerca de 6.000 espécies de árvores e 800 espécies de aves (BIOTA DE ORTHOPTERA DO BRASIL, 2022b; ICMBIO, 2022). O cerrado alberga cerca de 30% da fauna do Brasil e 5% fauna global. Devido a quantidade de espécies animais e vegetais que ocorrem neste bioma, o mesmo é considerado uma das 27 áreas críticas de biodiversidade do planeta com alto grau de endemismo, especial em relação à flora (ICMBIO, 2022). Estima-se que o Cerrado abriga cerca de 320.000 espécies de animais (ICMBIO, 2022).

A vegetação Cerrado é bastante diversificada, podendo ser classificada quando ocorre no interflúvio (cerrado lato sensu, campo rupestre, floresta mesofítica, campos litossólicos miscelâneos e vegetação de afloramento de rocha maciça) ou quando está associada aos cursos de água (florestas geleiras ou florestas de encosta, campo úmido, pantanal, brejos permanentes, plantas aquáticas e brejeiras, buritizais e veredas) (ICMBIO, 2022). O principal tipo de vegetação do Cerrado é o cerrado sensu lato, cobrindo cerca de 85% do bioma (ICMBIO, 2022). O cerrado sensu lato também pode se subdividir em outros tipos em função da ocorrência de árvores, arbustos e gramíneas, que são: campo limpo, campo sujo, cerrado sensu stricto e cerradão (ICMBIO, 2022).

As árvores do Cerrado desenvolveram longas raízes para na época seca alcançarem a água que se encontra disponível a cerca de 2m de profundidade, estas árvores também são caracterizadas por serem de pequeno porte e possuírem troncos retorcidos (BIOTA DE ORTHOPTERA DO BRASIL, 2022b).


O Cerrado possui um clima do tipo tropical, com variações médias das precipitações entre 750 a 2000 mm ao ano, porém em grande parte da região a variação média das precipitações é de 1100 a 1600 mm ao ano (ICMBIO, 2022). O bioma possui duas estações a saber: a estação seca (de maio a Setembro/outubro) e a estação chuvosa (de outubro a abril/maio), com variações médias de temperaturas anuais entre 18°C a 27°C, no entanto as temperaturas mínima e máxima podem atingir os 8°C e 34°C respectivamente (EMBRAPA, 2022; ICMBIO, 2022).

Quanto à hidrografia, o bioma tem particular importância por alimentar oito (8) das doze (12) regiões hidrográficas do Brasil, com ênfase especial às três grandes bacias hidrográficas dos rios Araguaia/Tocantins, São Francisco e rio Paraná (EMBRAPA, 2022).

Quanto à geologia, o cerrado é constituído por rochas do tipo sedimentares, magmáticas e metamórficas (EMBRAPA, 2022).

O bioma alberga cerca de 46 milhões de habitantes, sendo que a grande maioria está localizada em regiões metropolitanas na parte sudeste e centro-oeste. Além disso, o bioma também hospeda 95 territórios indígenas, 44 territórios quilombolas e 13 comunidades não indígenas (EMBRAPA, 2022).

Figura 4 – Mapa de localização do bioma Cerrado.



Fonte: O autor.

1.4 Trabalhos de campo nas áreas de estudo


1.4.1 Trabalho de campo em Valença/RJ

No período de 11 a 14/02 de 2019, uma equipa constituída por 10 pesquisadores vinculados à Embrapa Solos deslocou-se à Valença/RJ, nos arredores da Fazenda Santa

Mônica, região caracterizada principalmente por áreas de pastagens e formações florestais, com relevo montanhoso. Apesar de metade da equipe ter regressado ao Rio de Janeiro no dia 13/02, outra metade continuou as atividades de campo no dia seguinte (14/02). No período de 19 a 21/02 de 2019, uma equipe constituída por 4 pesquisadores vinculados à Embrapa Solos deslocou-se à Valença/RJ para a continuidade das atividades. O trabalho de campo decorreu em época chuvosa. Esta informação é bastante relevante, pois na época chuvosa as pastagens têm a tendência de apresentar maior biomassa relativamente à estação seca, podendo ocorrer por exemplo, em algumas áreas, uma transição na classificação das pastagens de um nível de degradação para outro menos severo (esta situação foi observada no campo pela segunda equipe de pesquisa). Devido a distância entre as regiões, percorreu-se as mesmas com o auxílio de dois veículos da Embrapa Solos, vide Figura 5.

Instituições envolvidas: Embrapa Solos, Programa de Mestrado em Engenharia de Biosistemas da UFF, Programa de Doutorado em Meio Ambiente da UERJ, entre outras.

Figura 5 – Dois (2) veículos da Embrapa Solos para apoio à equipe de campo.



Fonte: O autor.

Nas diversas propriedades rurais percorridas, as equipes identificaram pastagens do tipo *Brachiaria Decumbens* e Campim-Marandu (*Brachiaria Brizantha* (A. Rich)), com a ocorrência de espécies invasoras tais como: capim-sapé, entre outras.

Figura 6 – Algumas das propriedades rurais percorridas e amostradas.



Fonte: O autor.

Figura 7 – Identificação das pastagens e das plantas invasoras.



Fonte: O autor.

A grande maioria das áreas de pastagens visitadas estava sob pastejo, vide Figura 4.

Figura 8 – Pastagens sob pastejo.

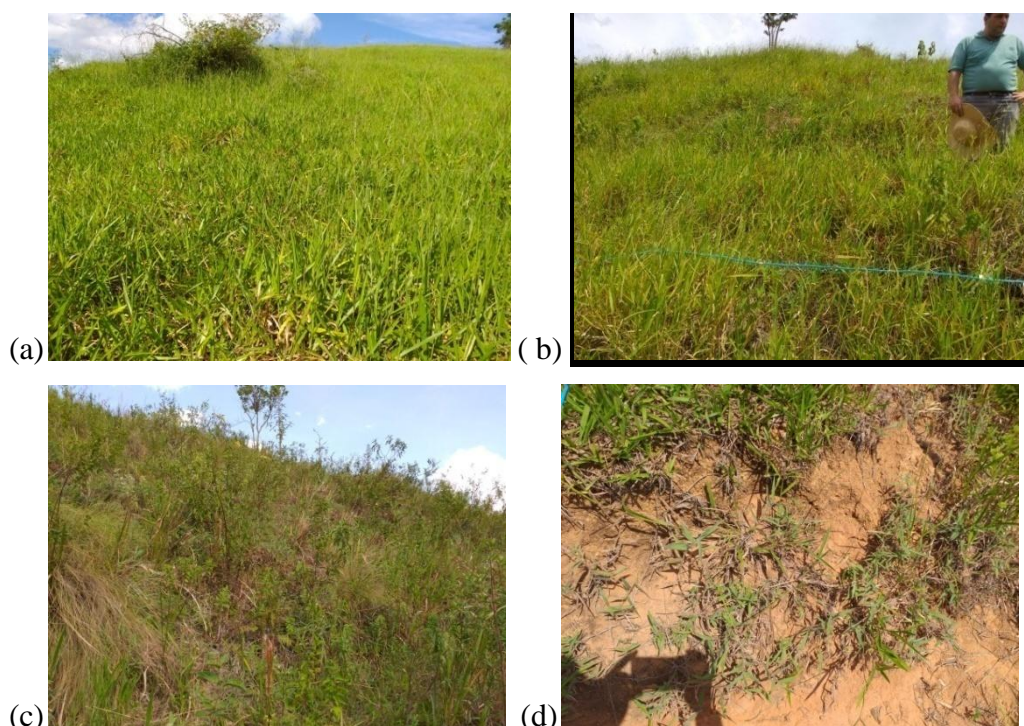


Fonte: O autor.

Os níveis de degradação das pastagens foram classificados segundo Dias-Filho, (2015), isto é, N1, N2, N3 e N4, ou seja, em função do vigor vegetativo, da ocorrência de solo descoberto e da presença de plantas invasoras (DIAS-FILHO, 2015).

A medida em que as propriedades rurais eram percorridas e os níveis de degradação das pastagens eram identificados coletavam-se também as coordenadas geográficas das respectivas áreas com dois GPS de mão (portáteis) dos tipos: Garmin GPS map60 CSx e Garmin etrex 30.

Figura 9 – Níveis de degradação das pastagens.



Legenda: (a) N1. (b) N2. (c) N3. (d) N4.

Fonte: O autor.

A coleta das amostras realizou-se ao longo de um transepto materializado por um fio de 50 metros com marcações vermelhas e amarelas, além de um gabarito (quadrado de ferro) de 50 cm x 50 cm. Esse transepto era posicionado sobre o caminho dos animais onde eram coletados pontos apenas numa das marcações, por exemplo, a vermelha, e posteriormente, coletava-se de forma rasteira toda a biomassa presente na área abrangida pelo gabarito sobre a pastagem. Posteriormente, posicionava-se o transepto num outro caminho dos animais, mas dessa vez eram coletados apenas os pontos nas marcações amarelas, de modo a garantir a aleatoriedade das amostras coletadas em campo, vide Figura 9.

Figura 10 – Coleta de amostras de pastagem ao longo de um transepto de 50 m com marcações aleatórias vermelhas e amarelas. O gabarito (quadrado de ferro) possui dimensões de 50 cm x 50 cm.



Fonte: O autor.

Realizou-se a medição de alturas em todas as áreas de pastagens amostradas, pois será útil na correlação entre a biomassa e a altura, tendo em consideração os níveis de degradação das pastagens, vide Figura 10.

Figura 11 – Medição de altura das pastagens.



Fonte: O autor.

Após a coleta dos dados em campo, realizou-se o trabalho de laboratório, isto é, o processo de triagem, a pesagem e a secagem do material na estufa com circulação forçada de ar à temperatura de 55°C durante 72h (DETMANN et al., 2012). Após esse período de tempo, o material seco deve ficar entre 30 a 40 minutos em espera para entrar em equilíbrio com a umidade relativa do ar, e seguidamente, ser pesado (DETMANN et al., 2012). O processo de triagem consiste na separação das folhas verdes, folhas secas e colmos, e posteriormente, na secagem desse material na estufa. A cada amostra coletada é separada 50% de amostra pura para ser pesada e posteriormente depositada na estufa para a secagem. Assim, o material triado corresponde aos restantes 50% de cada amostra coletada. O material não triado no mesmo dia da coleta foi conservado em freezer de modo a não sofrer alterações físico-químico-biológicas, conservando assim o conteúdo de umidade, vide Figura 11.

Figura 12 – Conservação das amostras de pastagem em freezer, processo de triagem, pesagem das amostras de pastagens separadas (50%) deposição de material na estufa de circulação forçada de ar.



Fonte: O autor.

1.4.1.2 A equipe de campo e de pesquisa

Ademir Fontana – Pesquisador da Embrapa Solos

Ana Carolina – Mestranda em Engenharia de Biosistemas na UFF

Fabiano Baliano – Pesquisador da Embrapa Solos

Guilherme Donagema – Pesquisador da Embrapa Solos

Marina Lima – Pós-Doutoranda em Zootecnia Embrapa Solos

Mateus Benchimol Ferreira de Almeida – Doutorando em Meio Ambiente na UERJ

Matheus Leal das Neves – Mestrando em Engenharia de Biosistemas na UFF

Natassia Armacolo – Doutoranda em Agronomia na Universidade Estadual de Londrina

Róberson Pimentel – Professor de Mestrado em Engenharia de Biosistemas na UFF

Tainá Linhares – Mestranda em Engenharia de Biosistemas na UFF

Margareth Simões - Pesquisadora da Embrapa Solos

Rodrigo Peçanha Demonte Ferraz – Pesquisador da Embrapa Solos

Renato Rodrigues – Pesquisador da Embrapa Solos

Figura 13 – A equipe de campo.



Fonte: O autor.

1.4.2 Pontos de campo coletados no bioma Cerrado

Os pontos de campo do bioma Cerrado utilizados nesta pesquisa científica foram coletados por uma equipe de pesquisadores do Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás (LAPIG) da Universidade Federal de Goiás. O Prof. Dr. Laerte Ferreira, Coordenador do LAPIG e Pesquisador da Rede MapBiomias, fez a cortesia de ceder estes pontos de campo tão valiosos para a presente científica. Para o bioma Cerrado, foram cedidos 400 pontos de campo (coletados em março,

abril e agosto de 2019) que posteriormente foram multiplicados em 4.212 pontos de campo com auxílio do *Google Earth* e Sistemas de Informação Geográfica.

No entanto, o LAPIG (assim como o MapBiomias) adota uma política de dados abertos, e deste modo, pouco tempo depois os dados foram disponibilizados para o acesso do público em geral.

Os dados também estão disponíveis em: <https://atlasdaspastagens.ufg.br/map>.

2 UMA ABORDAGEM DE SENSORIAMENTO REMOTO BASEADA EM IMAGENS SENTINEL-2 E SAR-SENTINEL-1 PARA O MAPEAMENTO DOS NÍVEIS DE DEGRADAÇÃO DE PASTAGENS: ESTUDO DE CASO NO BIOMA MATA ATLÂNTICA, BRASIL

Resumo

Este trabalho teve como objetivo desenvolver uma metodologia baseada em técnicas de Sensoriamento Remoto para o monitoramento e avaliação da qualidade das pastagens. A metodologia proposta, em relação as já existentes, apresenta como diferencial uma extensa análise exploratória de diversos índices de vegetação, texturas, imagens Sentinel-2 em bandas puras, bem como Declividade e imagens de radar nas polarizações VH e VV, e ademais se preocupa em identificar quais destes produtos de sensoriamento remoto são mais importantes no processo de degradação de pastagens. Dessa forma, de acordo com a literatura, os níveis de degradação das pastagens foram definidos como N1, N2N3 e N4, desde as pastagens mais vigorosas até as mais degradadas. A área de estudo corresponde a 1.089,9 km² e está localizada no interior do estado do Rio de Janeiro onde há ocorrência de degradação de pastagens, compreendendo os municípios de Valença, Vassouras, Rio das Flores, Barra do Pirai e Paty dos Alferes. Assim, realizou-se trabalhos de campo para coletar características biofísicas das pastagens *in situ*, como biomassa e altura. Usou-se imagens Sentinel-2, Sentinel-1 e Declividade (SRTM); também usou-se as amostras de campo; ademais, criou-se uma máscara de ocorrência das pastagens a partir do mapa de Uso e Cobertura da Terra versão 6 do MapBiomas que é indicada pelo valor de pixel 15; e, finalmente, realizou-se o processamento deste conjunto de dados no algoritmo de classificação supervisionada de imagens *Random Forest*. O processamento das imagens digitais foi feito em dois momentos: (1) No R (processamento auxiliar); e (2) no *Google Earth Engine* (processamento principal). No R, obteve-se informações sobre as imagens (camadas) mais importantes; e no *Google Earth Engine*, realizou-se o processamento das imagens mais importantes indicadas no R, para a obtenção dos resultados finais. O NCI foi a camada mais importante e o peso da biomassa a característica biofísica das pastagens mais importante, sendo que a correlação entre ambos foi $R^2 = 0,722$. A classificação supervisionada *random forest* no *Google Earth Engine* revelou que nesta área de estudo tem-se: N1 (52.72%), N2N3 (32.56%) e N4

(14.72%). As acurácias alcançadas foram as seguintes: Acurácia Global = 0,93; *Kappa* = 0,89; e *F-score* ($N1 = 0,97$, $N2N3 = 0,93$, $N4 = 0,88$). Finalmente, as metodologias propostas nesta pesquisa científica para as condições estudadas provaram ser robustas, eficientes e eficazes para o objetivo proposto da separabilidade dos níveis de degradação de pastagens por meio de técnicas de Sensoriamento Remoto.

2.1 Introdução

As pastagens degradadas têm sido uma grande preocupação no setor da pecuária a nível global, impactando diretamente na produtividade de carne, dada a demanda por alimentos que tem sido um problema cada vez mais evidente nos dias de hoje. Estima-se que a população global será de cerca de 8,5 bilhões de pessoas em 2030, 9,7 bilhões em 2050 e 10,9 bilhões em 2100 (ONU, 2019). Segundo a FAO, a demanda mundial por alimentos de origem animal aumentará nos próximos anos, devido ao crescimento populacional e ao aumento do consumo per capita (FAO, 2021, 2009). No Brasil, o pastejo é a principal fonte de nutrição do gado (Dias-Filho, 2015), portanto a qualidade das pastagens tem papel fundamental no aumento da produtividade de carne. A pecuária contribui nas emissões de gases de efeito estufa como dióxido de carbono (CO_2), metano (CH_4) e óxido nitroso (N_2O) (FAO, 2009). Segundo o IPCC, as atividades humanas têm tido um impacto sem precedentes nas emissões de gases de efeito estufa na atmosfera, contribuindo para o aquecimento global, que hoje está em torno de $1,07^\circ C$ acima dos níveis pré-industriais e existe a preocupação de conter o aquecimento global abaixo de $1,5^\circ C$ (IPCC, 2021). O Brasil, em sua Contribuição Nacionalmente Determinada (NDC) do Acordo de Paris, com base no ano de 2005, se comprometeu a reduzir as emissões de gases de efeito estufa em até 37% e 43% em 2025 e 2030 respectivamente, além de alcançar a neutralidade climática (emissões líquidas zero) em 2060 (Governo da República Federativa do Brasil, 2020, 2015).

O Brasil possui uma área de cerca de 150 milhões de hectares de pastagens (MapBiomass, 2021), correspondendo a aproximadamente 21% do território nacional (PARENTE; FERREIRA, 2018). Estima-se que cerca de 60% das pastagens no Brasil estão degradadas (LAPIG, 2018), sendo apontadas como principais causas de degradação o manejo inadequado (Dias-Filho, 2015, 2013), a falta de reposição de nutrientes, o excesso de lotação (Júnior e Vilela, 2002; Macedo, 2001), má-formação das pastagens, declínio da fertilidade do

solo por falta de adubação, uso excessivo de fogo, cigarrinhas-das-pastagens, morte do capim-marandu (*Brachiaria Brizantha* (A. Rich)) e manejo de pastagem incorreto (Dias-Filho e Andrade, 2005). Atualmente, o Brasil é líder mundial na produtividade agropecuária (Brasil, 2017). No ano 2020, o rebanho brasileiro atingiu cerca de 217 milhões de cabeças de gado (EMBRAPA, 2021). Com uma população de cerca de 213.000.000 habitantes (IBGE, 2021a), com base no Censo Demográfico de 2010 realizado pelo Instituto Brasileiro de Geografia e Estatística (IBGE, 2010), o país, por meio do Ministério da Agricultura, Pecuária e Abastecimento, se preocupa cada vez mais em garantir a segurança alimentar através do aumento da produtividade agropecuária, além do excedente necessário para a exportação, elevando a atuação do Brasil no mercado internacional (MAPA, 2021b), porém promovendo a agricultura sustentável, sem necessidade da expansão da fronteira agrícola para as regiões florestadas, em conformidade com os Objetivos de Desenvolvimento Sustentáveis (ODS) (MMA, 2017; UN, 2015). Esse esforço tem contado com o apoio do Ministério do Meio Ambiente.

A manutenção das pastagens é uma mais-valia ao meio ambiente, pois evita o avanço das fronteiras agrícolas e das próprias zonas de pastoreio às regiões florestadas, além de contribuir no sequestro de carbono da atmosfera. A intensificação da pecuária tem o potencial de reduzir as taxas de desmatamento na Amazônia Brasileira devido o decréscimo da demanda de novas terras agricultáveis (JAKIMOW et al., 2018). No Brasil, a pecuária e o desmatamento são as principais causas da emissão dos gases de efeito de estufa (GEE) na atmosfera (MALHI et al., 2008). Programas de suporte à políticas de manejo de terras, como o *Reducing Emissions from Deforestation and forest Degradation* + (REDD+) (FAO, 2007) e o programa Agricultura de Baixo Carbono (ABC) do Brasil (AMAZON ENVIRONMENTAL RESEARCH INSTITUTE, 2012; JAKIMOW et al., 2018; MAPA, 2012) e futuramente o ABC+ (MAPA, 2021a) necessitam de mapas detalhados das práticas de manejo das pastagens que descrevem a intensidade de uso da terra, melhor quantificação de carbono e as emissões dos gases de efeito estufa (JAKIMOW et al., 2018). Estima-se que a cada um hectare de pastagem recuperada corresponde a dois hectares de floresta em pé (DIAS-FILHO, 2015).

Assim, saber onde estão localizadas as pastagens degradadas e em que grau de degradação se encontram, é de grande importância ao nível do planejamento agrícola, pois será uma ferramenta essencial para os tomadores de decisão, permitindo a execução de projetos de recuperação de pastagens, identificando áreas prioritárias para a intervenção. Desta forma, o Sensoriamento Remoto apresenta-se como uma ferramenta adequada para esta tarefa, uma vez que algoritmos de processamento digital de imagens mais eficientes e

sensores cada vez mais potentes têm revolucionado esta área do conhecimento científico. Esta pesquisa faz parte do projeto GeoABC (Metodologias e Inovações Tecnológicas e o Planejamento da Agricultura de Baixa Emissão de Carbono em Apoio à Governança do Plano ABC), que trata do Plano ABC (Plano Setorial de Mitigação e de Adaptação às Mudanças Climáticas Visando à Consolidação de uma Economia de Baixa Emissão de Carbono na Agricultura), e visa avaliar métodos e técnicas inovadoras na área de Sensoriamento Remoto e integração de dados espaciais para a orientação de sistemas de produção agrícola alinhados à agricultura de baixa emissão de carbono (Ministério da Agricultura Pecuária e Abastecimento do Brasil, 2012).

O Sensoriamento Remoto tem sido aplicado com sucesso em estudos de avaliação da qualidade das pastagens (AGUIAR et al., 2017; GUERSCHMAN et al., 2009; NUMATA et al., 2007, 2008; PARENTE; FERREIRA, 2018; PEREIRA et al., 2018; ROBERTS; SMITH; ADAMS, 1993), porém existe a preocupação da obtenção de metodologias mais robustas, exatas e precisas que possibilitem a obtenção de resultados cada vez mais confiáveis que expressem com maior exatidão a realidade de campo. Duas abordagens principais têm sido utilizadas, isto é, índices de vegetação (AGUIAR et al., 2017; DELEGIDO et al., 2013; PARENTE; FERREIRA, 2018; PEREIRA et al., 2018) e a Análise de Mistura Espectral (ROBERTS; SMITH; ADAMS, 1993), ou mesmo uma combinação entre as duas abordagens (GUERSCHMAN et al., 2009; NUMATA et al., 2007, 2008). Nesta pesquisa científica, a metodologia proposta é baseada em séries temporais, índices de vegetação, classificação *random forest* e validação com amostras de campo. Esta pesquisa tem como objetivo propor uma metodologia de monitoramento e avaliação da qualidade das pastagens por meio de técnicas de Sensoriamento Remoto.

Sensoriamento remoto, inteligência artificial, computação paralela e computação em nuvem é uma combinação poderosa, pois constitui uma solução para o processamento de grandes volumes de dados; e o *Google Earth Engine* contém exatamente essas características em seu ambiente de computação. Até pouco tempo não era possível processar em poucos minutos um grande volume de imagens digitais de satélite, mas hoje em dia o *Google Earth Engine* tornou isso possível. O Sensoriamento Remoto deu um grande salto com a chegada do *Google Earth Engine* e aumentou o poder analítico e de processamento dos cientistas geoespaciais em suas pesquisas. Estudos mais elaborados e complexos agora são possíveis, abrindo-se uma janela de novas descobertas. Embora o *Google Earth Engine* seja tão poderoso, o R possui várias estatísticas que não estão disponíveis no *Google Earth Engine*, então é uma boa ideia combinar as duas ferramentas para obter um melhor desempenho do

processamento computacional e os melhores resultados possíveis. Phalke et al. (2020) exploraram muito bem a poderosa combinação de *Google Earth Engine* e R, e pretende-se fazer o mesmo neste estudo.

2.2 Revisão bibliográfica

2.2.1 Trabalhos relacionados

Um estudo muito interessante sobre o monitoramento da produtividade das pastagens usando dados Sentinel-2 é o trabalho de Dusseux et al., (2022) que utilizaram diversos índices de vegetação comuns, bandas espectrais individuais e combinações de bandas espectrais com base em fórmulas propostas pelos próprios autores para gerar características das pastagens que, por sua vez, foram correlacionadas com a altura da pastagem coleta em campo, tendo como base o ano de 2018 (DUSSEUX et al., 2022). Os resultados demonstraram que a melhor correlação alcançada foi obtida com base em uma das características (combinação de bandas espectrais) propostas pelos autores, denominada 3BSI (B7, B11, B6), sendo $R^2 = 0.58$ e EMQ = 2.13cm, superando as correlações realizadas com os índices de vegetação e as bandas espectrais individuais. Por meio de regressão linear, os autores também estimaram a altura das pastagens para o ano de 2020 e obtiveram $R^2 = 0.56$ e EMQ = 2.1cm (DUSSEUX et al., 2022).

Estudos de Parente and Ferreira (2018) da qualidade das pastagens do Brasil com base em uma série temporal de imagens MODIS de 2000 a 2016, a partir das quais foram calculados 90 métricas espectro-temporais oriundas das bandas Red (vermelho), NIR (infravermelho próximo) e SWIR1 (infravermelho médio 1), além de diversos índices de vegetação, aos quais aplicou-se a classificação supervisionada *random forest* que permitiu a geração de 17 mapas de pastagens com a acurácia geral de 80%, e concluíram que de 2000 a 2005 as áreas de pastagens do bioma Amazônia aumentaram em aproximadamente 15 milhões de hectares, já os biomas Cerrado, Caatinga e Pantanal o aumento foi de aproximadamente 8 milhões de hectares, somente a Mata Atlântica teve uma redução das áreas de pastagens (PARENTE; FERREIRA, 2018).

Pereira et al. (2018) desenvolveram um estudo de avaliação da qualidade das pastagens do bioma Cerrado com base em imagens MODIS de 2000 a 2017, utilizando a tendência cumulativa do NDVI (regressão linear) ao longo do tempo como um indicador das pastagens degradadas (PEREIRA et al., 2018). Nas tendências cumulativas de NDVI, valores de slope iguais a 0 foram considerados sem degradação, já valores de slope abaixo de 0 foram considerados degradado ou severamente degradado (PEREIRA et al., 2018). O estudo apontou que cerca de 39% das pastagens do Cerrado estão degradadas, o que corresponde a 18.2 milhões de hectares. Este estudo indicou também que os estados com maiores proporções de pastagens degradadas são GO, MG, MS e MT (PEREIRA et al., 2018).

Valle Júnior et al. (2019) desenvolveram um estudo de degradação das pastagens na Área de Proteção Ambiental (APA) da Bacia do Rio Uberaba (com 528.1 km², dos quais 50.9% é pastagem) localizada no estado de MG, com base em imagens NDVI-MODIS (250m) num período de 4 anos (2013-2016), as pastagens foram classificadas em saudáveis, levemente degradadas, moderadamente degradadas e degradadas (denominadas fisionomias), oriundas da relação não linear entre valores de NDVI e tempo (VALLE JÚNIOR et al., 2019). O mapa das pastagens degradadas foi obtido com base nas 23 imagens NDVI do ano de 2016, comparando com as fisionomias (VALLE JÚNIOR et al., 2019). Os resultados obtidos revelaram uma área de pastagens degradadas correspondentes a 160.1 km², ou seja, 60% das áreas de pastagens (VALLE JÚNIOR et al., 2019).

Hott et al. (2019) analisaram pastagens degradadas na Zona da Mata no estado de MG, usando imagens NDVI-MODIS (250m) de fevereiro de 2000 a maio de 2013, com base em métricas fenológicas, estatísticas temporais e análise multicritério (AHP). O estudo concluiu que cerca de 61.5% das pastagens da Zona da Mata estão degradadas (HOTT et al., 2019).

Reinermann et al. (2020) realizam uma vasta revisão bibliográfica sobre diversas metodologias para a avaliação da produtividade das pastagens (REINERMANN; ASAM; KUENZER, 2020).

2.2.2 Carotenoides

Os carotenoides e as clorofilas são os principais pigmentos das folhas verdes (GITELSON et al., 2002). Pigmentos são moléculas de uma planta verde típica que absorvem principalmente comprimentos de onda da região do visível (JENSEN, 2016). Os carotenoides

são uma classe de hidrocarbonetos em que, em função da sua estrutura química (linear ou ciclizada) e composição química (carbono, hidrogênio e com ou sem oxigênio), podem ser: carotenos lineares (Licopeno), carotenos ciclizados (β -Carotenos e α -Carotenos) e seus derivados oxigenados, isto é, xantofilas (luteína, zeaxantina, violaxantina, anteraxantina and neoxantina) (BISWAL, 1995; GITELSON et al., 2002). A clorofila a e a clorofila b são os pigmentos mais importantes na absorção da luz azul e vermelha, considerando que existem outros pigmentos nas células do mesófilo paliçádico mascarados pela abundância da clorofila (JENSEN, 2016). Entre esses pigmentos estão os carotenos amarelos e as xantofilas amareló-claras que absorvem principalmente a luz azul (JENSEN, 2016). Durante a senescência das folhas ou estresse da planta ocorre a degradação da clorofila e dos carotenoides (BISWAL, 1995). Com o desaparecimento dos pigmentos de clorofila, os carotenos e outros pigmentos se tornam dominantes (JENSEN, 2016). Alguns estudos revelam uma maior perda de clorofila do que carotenoides no processo de senescência das folhas, ocorrendo a alta retenção dos carotenoides, o que se caracteriza pela coloração amarelada (BISWAL, 1995). Tal fato ocorre provavelmente, devido a função protetora dos carotenoides contra os efeitos prejudiciais da irradiação da luz azul (GITELSON et al., 2002; MERZLYAK; GITELSON, 1995). Os licopenos realizam função protetora total à 0% de oxigênio e nenhuma função protetora à 100% de oxigênio quando expostos à alta energia de radiação γ (YOUNG; LOWE, 2018). Possivelmente, a luteína e a neoxantina somente funcionam como pigmentos acessórios na absorção fotossintética da luz, desempenhando função principal na proteção da clorofila a de fotooxidação dentro ou nas proximidades do centro de reação (Lichtenthaler). As xantofilas desempenham funções de coleta de luz e fotoproteção, já o β -caroteno é encontrado no centro de reação desempenhando função protetora (YOUNG; LOWE, 2018). Os carotenoides também têm a função de proteger a clorofila e os cloroplastos da fotooxidação (BISWAL, 1995). Estudos mais aprofundados sobre os carotenoides podem ser encontrados na literatura, tais como Biswal (1995), Demmig-Adams et al. (1996), Gitelson et al. (2002), Lichtenthaler (1987), Young and Lowe (2018), entre outros.

2.3 Metodologia

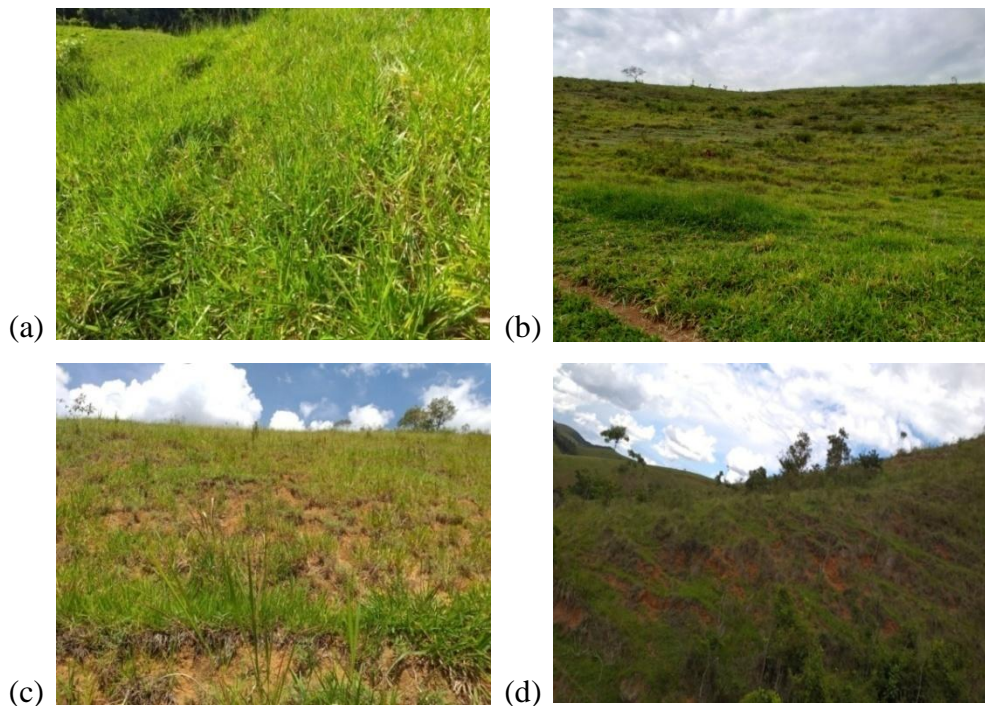
2.3.1 Área de estudo

A área de estudo corresponde a 1.089,9 km² e compreende os municípios de Valença, Vassouras, Rio das Flores, Barra do Piraí e Paty dos Alferes. É uma região de ocorrência de pastagens no Vale do Rio Paraíba do Sul, no estado do Rio de Janeiro (RJ), conforme a Figura 16. Nesta área existe a fazenda Santa Mônica (Fazenda Experimental da Embrapa) localizada no distrito Barão de Juparanã, no município de Valença (RJ), na qual um experimento de campo já está montado para calibrar as pastagens *in situ*.

As pastagens, *in situ*, foram classificadas em N1, N2, N3 e N4 (Figura 14), de acordo aos parâmetros definidos por Dias-Filho (2015), conforme a Tabela 3. *In situ*, observou-se que as pastagens estavam sob pastejo, conforme a Figura 15.

A área de estudo é caracterizada pela existência de um relevo acentuado, conforme a Figura 16. Esta representação tridimensional foi realizada com base em imagens Sentinel-2 e SRTM.

Figura 14 – Níveis das pastagens degradadas.



Legenda: (a) N1. (b) N2. (c) N3. (d) N4.

Fonte: O autor.

Figura 15 – Pastagens sob pastejo.



Fonte: O autor.

In situ, coletou-se 20 amostras de biomassa das pastagens e as alturas correspondentes. Em laboratório, pesou-se a biomassa e separou-se o material morto. Também foram reconhecidos e coletados vários outros pontos por GPS, como se apresenta na Tabela 3.

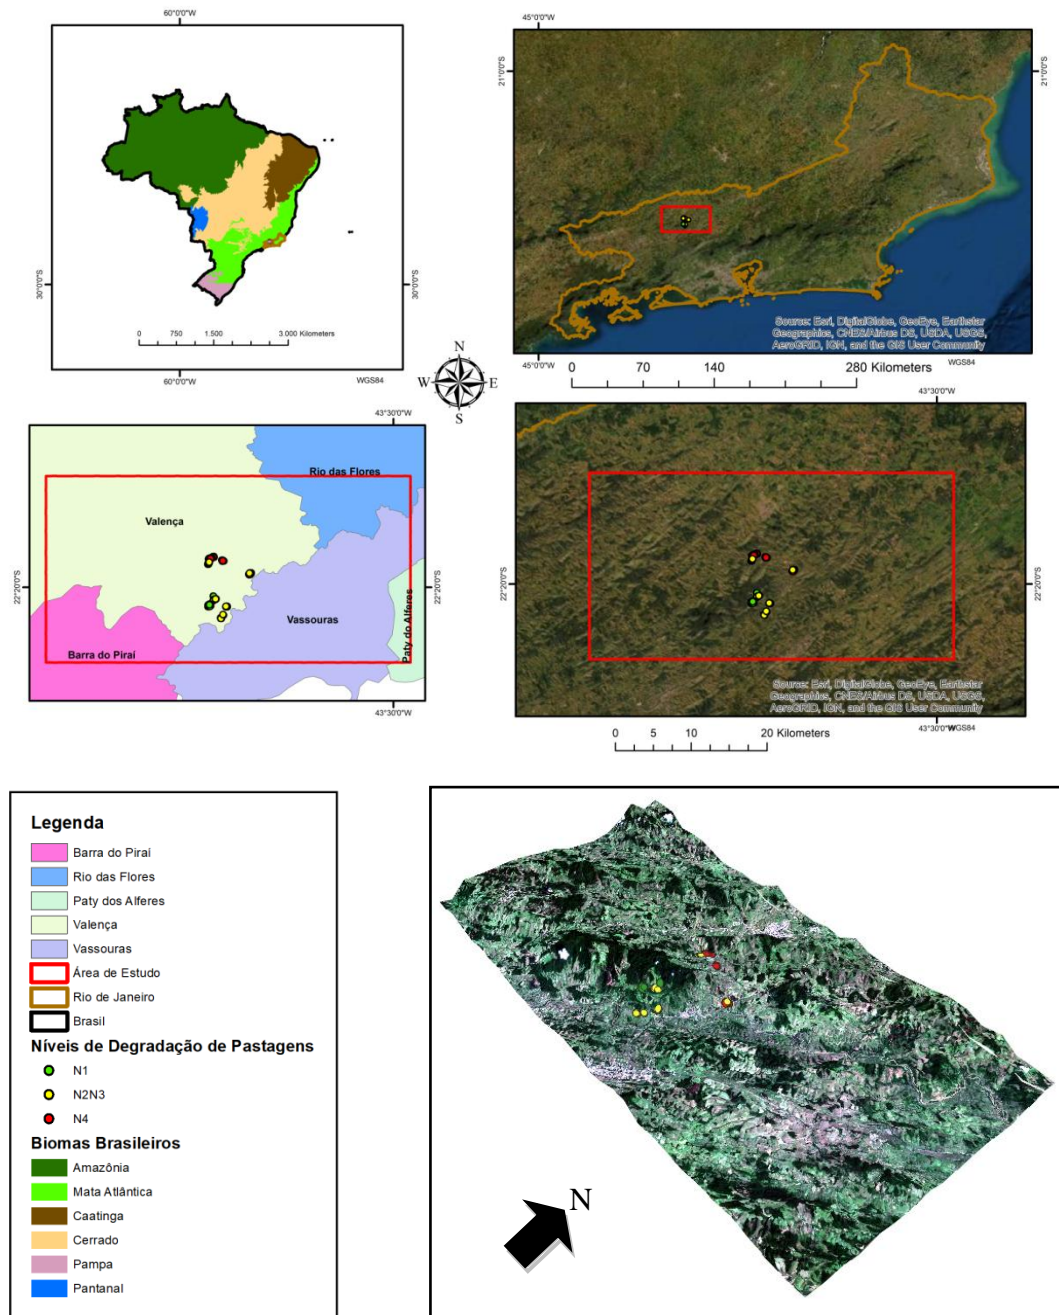
Nas diversas fazendas visitadas, foram identificadas pastagens do tipo *Brachiaria Decumbens* e Campim-Marandu (*Brachiaria Brizantha* (A. Rich)), com a ocorrência de espécies invasoras.

Tabela 3 – Informação das amostras de campo.

Nível de Degradação	Nº de amostras de campo	Total	Data de aquisição
N1	65	277	fev/2019: 11 a 14
N2N3	124		fev/2019: 19 a 21
N4	90		

Fonte: O autor.

Figura 16 – Mapa de localização, legenda e representação tridimensional.



Fonte: O autor.

2.3.2 Materiais

Para a preparação da presente pesquisa, os seguintes materiais foram necessários:

- 3 imagens Sentinel-2, conforme a Tabela 4, no sistema *Military Grid Reference System* (MGRS);
- Dados vetoriais (formato shapefile) do Brasil (IBGE, 2021b);
- 277 pontos georreferenciados de pastagens degradadas nos níveis N1, N2, N3 e N4, respectivamente, leve, moderado, forte e muito forte, da área de estudo. Os trabalhos de campo foram realizados de 11 a 14 de fevereiro de 2019 e de 19 a 21 de Fevereiro de 2019;
- Softwares: R, para o processamento digital de imagens auxiliar; QGIS 3 e ArcGIS 10, para a produção de mapas; e *Microsoft Office Excel 2007*, para correlação entre os índices de vegetação e as amostras de campo; *Power BI* para gráficos.
- Câmara de celular, para tirar fotos *in situ*;
- *Google Earth Engine*, para o processamento principal das imagens digitais. No *Google Earth Engine*, usou-se também: série temporal Sentinel-2 (1 ano), série temporal Sentinel-1 (1 ano), Declividade (Slope) a partir do SRTM, mapa de uso e cobertura da terra do Brasil do MapBiomas (versão 6) e imagens diárias de precipitação CHIRPS (1 ano).

Tabela 4 – Informação das imagens Sentinel-2 utilizadas.

Orbita (MGRS)	Data de aquisição
	29/01/2019
T23KPR	23/02/2019
	10/03/2019

Fonte: O autor

2.3.3 Métodos

Neste estudo, processou-se imagens no R (processamento auxiliar) e no *Google Earth Engine* (processamento principal), conforme a explicação a seguir.

No R, foram utilizadas 3 imagens Sentinel-2, conforme Tabela 4; As bandas utilizadas foram as seguintes: B2 (azul), B3 (verde), B4 (vermelho), B5 (borda vermelha), B6 (borda vermelha), B7 (borda vermelha), B8 (infravermelho próximo), B8A (infravermelho próximo), B11 (infravermelho médio 1), B12 (infravermelho médio 2). A correção atmosférica foi

realizada no Sen2Cor (*plugin* de correção atmosférica de imagens Sentinel-2) (ESA, 2022h). O Sen2Cor aplica um modelo de transferência radiativa para realizar a correção atmosférica para imagens Sentinel-2 (MUELLER-WILM; DEVIGNOT; PESSIOT, 2016). Com as imagens indicadas na Tabela 4, calculou-se os índices de vegetação da Tabela 5 e as texturas GLCM (Texture8). As bandas puras, os índices de vegetação e as texturas GLCM (Texture8) totalizam 315 camadas. A seguir, aplicou-se a máscara da área de estudo, a máscara das áreas de pastagens e a remoção dos pixels de nuvens a partir de imagens previamente classificadas, detectando pixels de nuvens e gerando uma máscara. Assim, foram inseridas 315 camadas no R, além dos 277 pontos de campo (no formato *shapefile*), conforme Tabela 3, e em seguida realizou-se a classificação supervisionada *random forest* (usando o pacote do R denominado *randomForest*).

Ao realizar dois processamentos digitais de imagens, tanto no R quanto no *Google Earth Engine*, a ideia foi aproveitar o melhor das duas ferramentas, isto é, o R que é uma ferramenta útil de processamento digital de imagens e possui poderosas ferramentas estatísticas; e o *Google Earth Engine* que é um excelente ambiente de processamento digital de imagens, permitindo o processamento de volumosos cubos de dados em tempo recorde, mas ainda tem em falta certos recursos estatísticos, como por exemplo, a indicação das camadas (*layers*) de maior importância.

O processamento no *Google Earth Engine* consistiu primeiramente na replicação do experimento realizado no R, conforme a Tabela 6, linha 3 (30 camadas mais importantes). Considerando que no *Google Earth Engine* existe a limitação de processamento de determinado volume de dados por usuário, e que neste estudo existe a preocupação de se trabalhar com séries temporais, não se calculou todos os índices de vegetação que foram calculados no R, apenas foram calculados os mesmos produtos de sensoriamento remoto correspondentes à linha 3 da Tabela 6 (30 camadas mais importantes), bem como o acréscimo da série temporal de imagens (ao invés de 3 meses, usou-se 1 ano), o que se achou ser de grande importância quando se trabalha com algoritmos de aprendizado de máquina tal como o *random forest*. Assim, as camadas (*layers*) usadas no *Google Earth Engine* foram as seguintes: B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12, NCI, CRI2, STI, CAI, NDTI, Vgreen, CRI1, RGR, NDI7, REP, TVI, Transformação “Tasseled Cap” de Kauth-Thomas (brilho, verdor e umidade), Texturas₁₈, VV (SAR-Sentinel-1), VH (SAR-Sentinel-1) e Declividade (a partir do SRTM).

No *Google Earth Engine*, a metodologia principal deste capítulo consistiu em processar 1 ano (2019) de séries temporais de imagens Sentinel-2, 1 ano de séries temporais

de imagens Sentinel-1, Declividade calculada a partir do SRTM, máscara de pixels de pastagens obtidas a partir da coleção 6 do Mapa de Uso Cobertura da Terra do MapBiomias para os anos 2019, 277 pontos de amostras de campo coletadas no correspondente ano e uma máscara da área de estudo, conforme Figura 17.

Primeiramente, aplicou-se a máscara da área de estudo em todos os produtos de sensoriamento remoto usados nesta metodologia. Na etapa de pré-processamento, aplicou-se um filtro de remoção de nuvens nas imagens Sentinel-2, a partir do qual, pixels cobertos de nuvens foram removidos da série temporal, permitindo assim, apenas o processamento de pixels livres de nuvens (em boas condições atmosféricas). A partir da série temporal das imagens Sentinel-2 filtradas (livres de nuvens), calculou-se todos os índices de vegetação indicados na Tabela 5. Aproveitou-se a mesma série temporal Sentinel-2 (livres de nuvens) e aplicou-se mediana de 3 em 3 meses, isto é, median1 (Jan-Mar), median2 (Abr-Jun), median3 = (Jul-Set) e median4 = (Out – Dez). Deste modo, foi possível reduzir a dimensionalidade da série temporal Sentinel-2 e calcular as texturas GLCM.

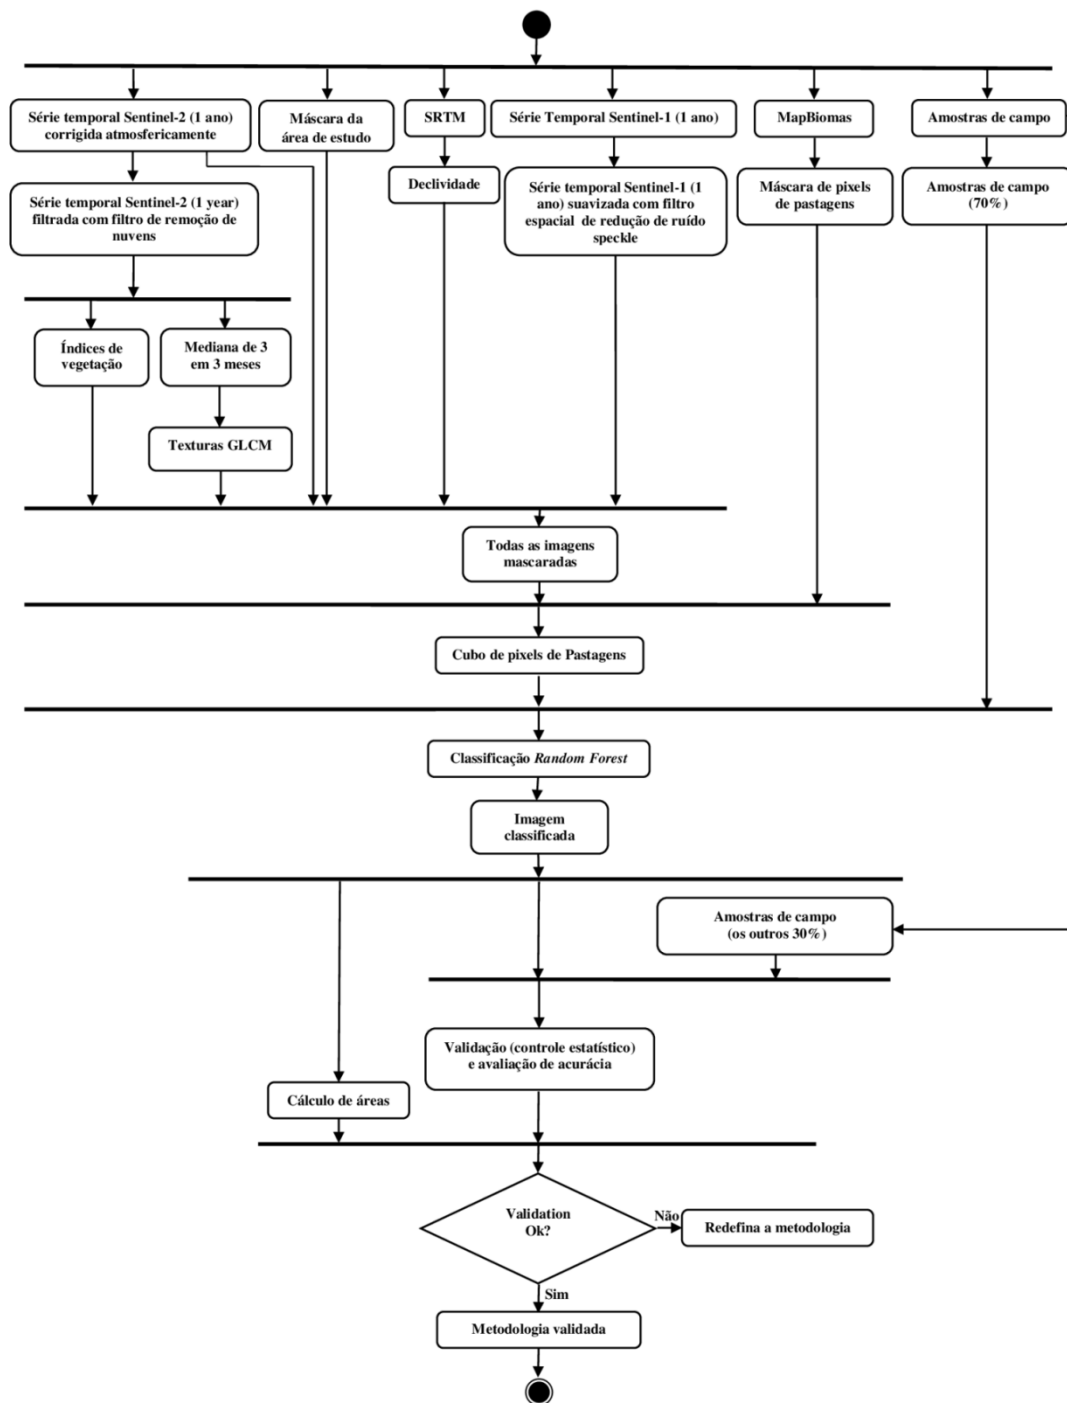
As séries temporais Sentinel-1 utilizadas nesta pesquisa científica correspondem às imagens Ground Range Detected (GRD), na banda C (comprimento de onda de 6 cm), com polarizações VV e VH, cujo tamanho do pixel é 10m x 10m. As imagens GRD já são corrigidas das distorções advindas da geometria do imageamento de radar, assim sendo, não houve necessidade de se realizar quaisquer correções sobre estas imagens. O pré-processamento das séries temporais Sentinel-1 consistiu na aplicação de um filtro morfológico de média que usa um kernel para a suavização de ruído speckle. Com base nos testes realizados, estabeleceu-se o raio deste kernel em 30m.

O MapBiomias tem realizado anualmente o mapeamento do uso e ocupação da terra de todo o território brasileiro, por meio de séries temporais (Landsat-8), aprendizado de máquina (*random forest*), computação em nuvem e computação paralela (*Google Earth Engine*), sendo que a classe pastagem consta neste mapeamento, correspondendo aos pixels de valor 15. Deste modo, foi possível a obtenção da máscara de pastagens da área de estudo.

Criou-se um cubo de dados com todos os produtos de sensoriamento remoto mencionados e aplicou-se a máscara das pastagens. Agora, tem-se um cubo de pixels correspondentes às áreas de pastagens na área de estudo. Com o cubo de pixels (pastagens) e 70% das amostras de campo, realizou-se a classificação *random forest*, dando como resultados uma imagem classificada nas 3 classes: N1, N2N3 e N4. As classes N2 e N3 foram agrupadas em uma única classe, porque têm respostas espectrais muito próximas.

Após a obtenção da imagem classificada, realizou-se a validação usando os restantes 30% das amostras de campo. Na etapa de validação, realizou-se o controle estatístico e a avaliação da acurácia do mapa final. Sendo satisfatória a validação do mapa final, calculou-se as estatísticas e exportou-se o mapa final.

Figura 17 – Fluxograma da metodologia proposta no Google Earth Engine (processamento principal).



2.3.3.1 Índices de Vegetação

Na metodologia deste estudo, nós usámos os seguintes índices de vegetação:

CAI (Cellulose Absorption Index) é baseado nas características de absorção na região dos 2000 aos 2200 nm devido a celulose e lignina na biomassa da planta (GUERSCHMAN et al., 2009; HILL, 2013). CRI1 (Carotenoid Reflectance Index 1) é um índice que estima o conteúdo total de carotenoides nas folhas das plantas (GITELSON et al., 2002; HILL, 2013). DFI (Dead Fuel Index) é um índice indicador de plant residue (DINGAAN; TSUBO, 2019; LI; GUO, 2016). EVI (Enhanced Vegetation Index) ou EVI2 (Enhanced Vegetation Index 2) é um NDVI melhorado, permitindo um melhor monitoramento da vegetação, devido a redução da influência do sinal do substrato abaixo do dossel, bem como a redução dos efeitos atmosféricos (HUETE, 1999). Este índice possui maior sensibilidade que o NDVI em regiões de alta biomassa (WARDLOW; EGBERT; KASTENS, 2007). Alguns estudos apontaram maior sensibilidade do EVI em comparação com o NDVI no pico do crescimento da lavoura (JIANG et al., 2008). Kauth-Thomas Tasselad Cap Transformation tem a finalidade de mensurar os componentes essenciais dos solos, tais como: brightness, greenness and wetness (CRIST; KAUTH, 1986; KAUTH, 1976; KAUTH et al., 1979; SHI; XU, 2019). MSAVI (Modified Soil Adjusted Vegetation Index) é um SAVI modificado que usa um L iterativo que melhora o ajuste do solo e aumenta o intervalo dinâmico do SAVI (QI et al., 1994). NCI (Normalized Canopy Index) é um índice que serve para estimar o GBR (Green Biomass Ratio) nas pastagens. GBR é a razão entre a biomassa verde acima do solo e o total de biomassa acima do solo (plantas verdes, mortas e liteira) (LI; GUO, 2016; REN; ZHOU, 2019). NDI5 (Normalized Difference Index 5) é um índice que serve para estimar o crop residue (DINGAAN; TSUBO, 2019; LI; GUO, 2016). NDI7 (Normalized Difference Index 7) é um índice que serve para estimar o crop residue (DINGAAN; TSUBO, 2019; LI; GUO, 2016). NDSVI (Normalized Difference Senescent Vegetation Index) é um índice sensível à vegetação senescente (QI et al., 1994). NDTI (Normalized Difference Tillage) é um índice que foi desenvolvido para distinguir as condições da superfície do solo do NDRI (Normalized Difference Residue Index), que é um índice de crop residue (DINGAAN; TSUBO, 2019; LI; GUO, 2016; VAN DEVENTER et al., 1997). NDVI (Normalized Difference Vegetation Index) é um índice que fornece importantes informações sobre a biomassa, tais como: saúde da vegetação verde e monitoramento de mudanças sazonais e interanuais no crescimento e

atividade da vegetação (HUETE et al., 2002; ROUSE et al., 1973). NDWI or NDMI (Normalized Difference Moisture or Water Index) é um índice que é altamente correlacionado com o conteúdo de água do dossel e rastreia mais profundamente mudanças na biomassa da planta e estresse hídrico do que o NDVI (GAO, 1996). REP (Red Edge Position) é fortemente correlacionado com o conteúdo de clorofila foliar e pode ser um indicador sensível do estresse da vegetação (CLEVERS, 1994). RGR (Red-Green Ration) é um índice que estima a proporção de anthocyanin (pigmentos que em grandes quantidades produzem a coloração avermelhada nas folhas) por clorofila durante o desenvolvimento da folha (HILL, 2013; SIMS; GAMON, 2002). SATVI (Soil Adjusted Total Vegetation Index) é um índice sensível tanto à vegetação verde quanto à vegetação senescente (LI; GUO, 2016; MARSETT et al., 2006). SAVI (Soil Adjusted Vegetation Index) é um índice que conserva as características do NDVI, porém possui um fator de ajuste para o sustrato abaixo do dossel (L) (HUETE, 1988). SR (Simple Ratio) é um índice que fornece informações sobre a biomassa e o LAI (BIRTH; MCVEY, 1968). STI (Soil Tillage Index) é um índice indicador de crop residue (DINGAAN; TSUBO, 2019). TVI (Triangular Vegetation Index) é um índice desenvolvido para estimar a energia radiativa absorvida pelos pigmentos nas folhas da planta (BROGE; LEBLANC, 2001; PEÑA-BARRAGÁN et al., 2011). Vgreen (Green Vegetation Index) é um índice usado para monitorar as condições da vegetação e a estrutura da planta, mostrando diferentes respostas entre crops com dossel aberto ou fechado (DAUGHTRY et al., 2005; PEÑA-BARRAGÁN et al., 2011).

Tabela 5 – Índices de Vegetação para o Sentinel-2.

Índice de Vegetação	Fórmula equivalente Sentinel-2	Referências
Cellulose Absorption Index (CAI)	$B7/B6$	(GUERSCHMAN et al., 2009; HILL, 2013)
Carotenoid Reflectance Index 1 (CRI1)	$(1/B2) - (1/B3)$	(GITELSON et al., 2002; HILL, 2013)
Carotenoid Reflectance Index 2 (CRI2)	$(1/B2) - (1/B5)$	(GITELSON et al., 2002)
Dead Fuel Index (DFI)	$100(1 - B7/B6)/(B4/B5)$	(DINGAAN; TSUBO, 2019; LI; GUO, 2016)
Enhanced Vegetation Index (EVI)	$(2.5(B8 - B4))/(B8 + 6B4 - 7.5B2 + 1)$	(HUETE, 1999)
Enhanced Vegetation Index (EVI2)	$(2.5(B5 - B4))/(B5 + 2.4B4 + 1)$	(JIANG et al., 2008)
Kauth-Thomas Tasselad Cap Transformation	$B = 0.3510B2 + 0.3813B3 + 0.3437B4 + 0.7196B8 + 0.2396B11 + 0.1949B12$ $G = -0.3599B2 - 0.3533B3 - 0.4734B4 + 0.6633B8 + 0.0087B11 - 0.2856B12$ $W = 0.2578B2 + 0.2305B3 + 0.0883B4 + 0.1071B8 - 0.7611B11 - 0.5308B12$	(CRIST; KAUTH, 1986; KAUTH, 1976; KAUTH et al., 1979; SHI; XU, 2019)
Green Vegetation Index (Vgreen)	$(B3 - B4)/(B3 + B4)$	(DAUGHTRY et al., 2005; PEÑA-BARRAGÁN et al., 2011).
Modified Soil Adjusted Vegetation Index (MSAVI)	$2B8 + 1 - \sqrt{(2B8 + 1)^2 - 8(B8 - B4)}$	(QI et al., 1994)
Normalized Canopy Index (NCI)	$(B6 - B3)/(B6 + B3)$	(LI; GUO, 2016; REN; ZHOU, 2019)
Normalized Difference Index (NDI5)	$(B5 - B6)/(B5 + B6)$	(DINGAAN; TSUBO, 2019; LI; GUO, 2016)
Normalized Difference Index (NDI7)	$(B5 - B7)/(B5 + B7)$	(DINGAAN; TSUBO, 2019; LI; GUO, 2016)
Normalized Difference Moisture or Water Index (NDWI or NDMI)	$(B8 - B11)/(B8 + B11)$	(GAO, 1996)
Normalized Difference Senescent Vegetation Index (NDSVI)	$(B6 - B4)/(B6 + B4)$	(LI; GUO, 2016; QI et al., 2002)
Normalized Difference Tillage Index (NDTI)	$(B6 - B7)/(B6 + B7)$	(DINGAAN; TSUBO, 2019; LI; GUO, 2016; VAN DEVENTER et al., 1997)
Normalized Difference Vegetation Index (NDVI)	$(B5 - B4)/(B5 + B4)$	(HUETE et al., 2002; ROUSE et al., 1973)
Red Edge Position (REP)	$700 + 40(B_{red\ edge} - B5)/(B6 - B5)$	(CLEVERS, 1994)
Red-Green Ration (RGR)	$B_{red\ edge} = (B4 + B7)/2$ $B4/B3$	(HILL, 2013; SIMS; GAMON, 2002)
Simple Ratio (SR)	$B8/B4$	(BIRTH; MCVEY, 1968)
Soil Adjusted Total Vegetation Index (SATVI)	$2(B6 - B4)/(B6 + B4 + 1) - B7/2$	(LI; GUO, 2016; MARSETT et al., 2006)
Soil Adjusted Vegetation Index (SAVI)	$2(B5 - B4)/(B5 + B4 + 1)$	(HUETE, 1988)
Soil Tillage Index (STI)	$B6/B7$	(DINGAAN; TSUBO, 2019)
Triangular Vegetation Index (TVI)	$0.5((120(B8 - B3)) - 200(B4 - B3))$	(BROGE; LEBLANC, 2001; PEÑA-BARRAGÁN et al., 2011)

Fonte: O autor.

2.3.3.2 Texturas GLCM

Neste estudo, foram realizadas as seguintes combinações das texturas GLCM (Gray Level Co-occurrence matrices) (CONNERS; TRIVEDI; HARLOW, 1984; HARALICK; DINSTEIN; SHANMUGAM, 1973):

- Textura₁: 1 textura GLCM, i.e, variância.
- Textura₂: 2 texturas GLCM, i.e., variância e média (bom desempenho no R na metodologia deste estudo);
- Textura₃: 3 texturas GLCM, i.e, entropia, correlação e contraste (CLAUSI, 2002);
- Textura₈: 8 principais texturas GLCM, i.e, segundo momento angular, contraste, correlação, dissimilaridade, entropia, homogeneidade, variância e média (HARALICK; DINSTEIN; SHANMUGAM, 1973; WOOD et al., 2012).
- Textura₁₈: 18 texturas GLCM, i.e, segundo momento angular, contraste, correlação, variância, diferença inversa do momento, soma da média, soma da variância, soma da entropia, entropia, diferença da variância, diferença da entropia, medidas de informação de correlação 1, medidas de informação de correlação 2, máximo coeficiente de correlação, dissimilaridade, inércia, sombra do cluster, proeminência do cluster (CONNERS; TRIVEDI; HARLOW, 1984; HARALICK; DINSTEIN; SHANMUGAM, 1973; WOOD et al., 2012) – melhor resultado no Google Earth Engine na metodologia deste estudo –.

2.4 Resultados e discussões

Existem dois grupos de resultados nesta pesquisa, i.e, os resultados obtidos no R (processamento auxiliar) e os resultados obtidos no *Google Earth Engine* (processamento principal). Houve necessidade de realizar um processamento auxiliar de imagens Sentinel-2

no R, devido a disponibilidade de ferramentas estatísticas bastante úteis que permitem um melhor entendimento do fenômeno de degradação de pastagens, bem como uma melhor extração dos resultados.

2.4.1 Processamento digital de imagens no R (processamento auxiliar)

Com base nas 315 camadas (*layers*), a classificação supervisionada *random forest* forneceu bons resultados de Acurácia Geral (AG = 0.92) e índice *Kappa* (K = 0.87), conforme Tabela 6. Esta primeira classificação supervisionada *random forest* permitiu identificar as camadas mais importantes do processo de degradação de pastagens por meio de uma função (*varImp*) que detecta a ordem de importância das camadas na classificação *random forest*, conforme a Figura 18. Deste modo, foi possível identificar que o índice de vegetação mais importante no processo de degradação de pastagens é o NCI (Normalized Canopy Index), cuja fórmula consta na Tabela 5. Ademais, este índice de vegetação mais importante (NCI) é produto de uma imagem Sentinel-2 cuja data de aquisição (29/01/2019) foi a mais próxima da data da coleta dos dados de campo (11/02/2019) comparando com a data de aquisição das demais imagens, o que reforça a consistência dos resultados obtidos. Para um entendimento mais profundo sobre *random forest*, recomenda-se a leitura dos estudos de BREIMAN (2001) e BREIMAN et al., (2014).

O *random forest* foi o algoritmo de classificação supervisionada selecionado nesta pesquisa científica, porque é robusto em relação a grandes volumes de dados, bem como indica as imagens mais importantes durante o processo de classificação, ademais tem demonstrado bom desempenho em diversos estudos de sensoriamento remoto (GUO et al., 2011; PAL, 2005; RODRIGUEZ-GALIANO et al., 2012a, 2012b).

O gráfico da Figura 18 (a) mostra a divisão do conjunto de camadas (*layers*) com base nos valores de *mtry* obtidos no processo de classificação supervisionada *random forest* das 315 camadas (*layers*). Assim, de acordo com os valores de *mtry* = 158 (camadas) e *mtry* = 2 (camadas) foram testados conjuntos de 158 camadas (*layers*) e 2 camadas (*layers*), sendo que as acurácias foram respectivamente (AG = 0.93; K = 0.89) e (AG = 0.67; K = 0.50).

A partir da ordem de importância das 315 camadas processadas no R com a classificação supervisionada *random forest* foram selecionadas 30 camadas. Com essas 30 camadas, realizou-se novamente a classificação supervisionada *random forest* no R e também

se obtive bons resultados ($AG = 0.89$ e $K = 0.83$), conforme Tabela 6. Embora a qualidade dos índices de acurácia é ligeiramente baixa, os resultados são quase similares com a vantagem do baixo custo computacional.

Com base no gráfico da Figura 18(b), realizou-se a classificação supervisionada *random forest* da camada mais importante (NCI), conforme Tabela 6.

Contudo, quando se realiza no R a classificação supervisionada *random forest* apenas da camada mais importante (NCI), os resultados não são satisfatórios, conforme Tabela 6, obtendo-se uma acurácia pobre com $AG = 0.61$ e $K = 0.39$. Assim, apenas o NCI não é suficiente para separar espectralmente as classes N1, N2N3 e N4, é necessário adicionar outros produtos ou camadas (*layers*) para melhorar a qualidade da classificação supervisionada *random forest*.


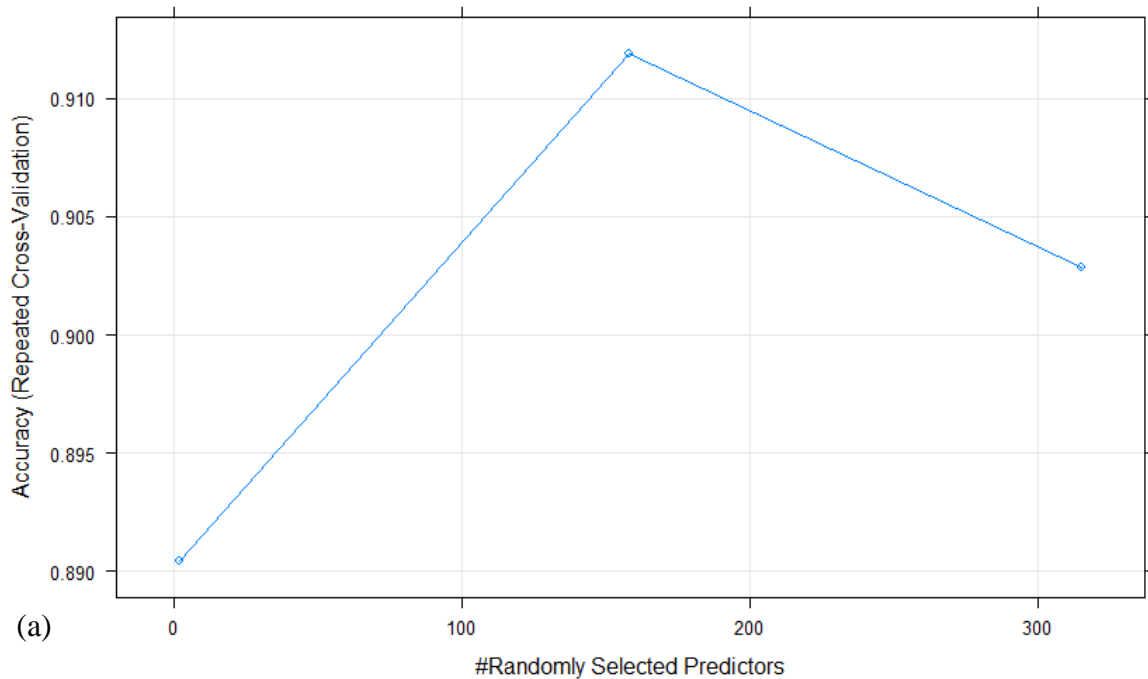
Este foi o processamento auxiliar no R. O próximo passo foi replicar a metodologia no *Google Earth Engine*, mas sem a necessidade de calcular todos os índices de vegetação de novo, apenas usando as camadas principais (*layers*), de acordo com os resultados obtidos no processamento auxiliar no R.

Tabela 6 – Testes de classificação supervisionada *random forest* e acurácias (AG e K) no R.

Série temporal	Número de camadas	Acurácia Geral (AG)	Kappa (K)
(Jan – Mar) 2019	315 (todas as camadas; a partir de $mtry = 315$; conforme Figura 18(a))	0.92	0.87
	158 (a partir de $mtry = 158$; conforme Figura 18(a))	0.93	0.89
	30 (mais importantes; conforme Figura 18(b))	0.89	0.83
	2 (a partir de $mtry = 2$; conforme Figura 18(a))	0.67	0.50
	1 (a mais importante: NCI; conforme Figura 18(b))	0.61	0.39

Fonte: O autor.

Figura 18 – Processamento das 315 camadas (layers) no R.



Legenda: (a) Acurácias de acordo com os valores de *mtry*. (b) Ordem de importância das 315 camadas (*layers*) processadas no R com o algoritmo de classificação supervisionada *random forest*.

Fonte: O autor.

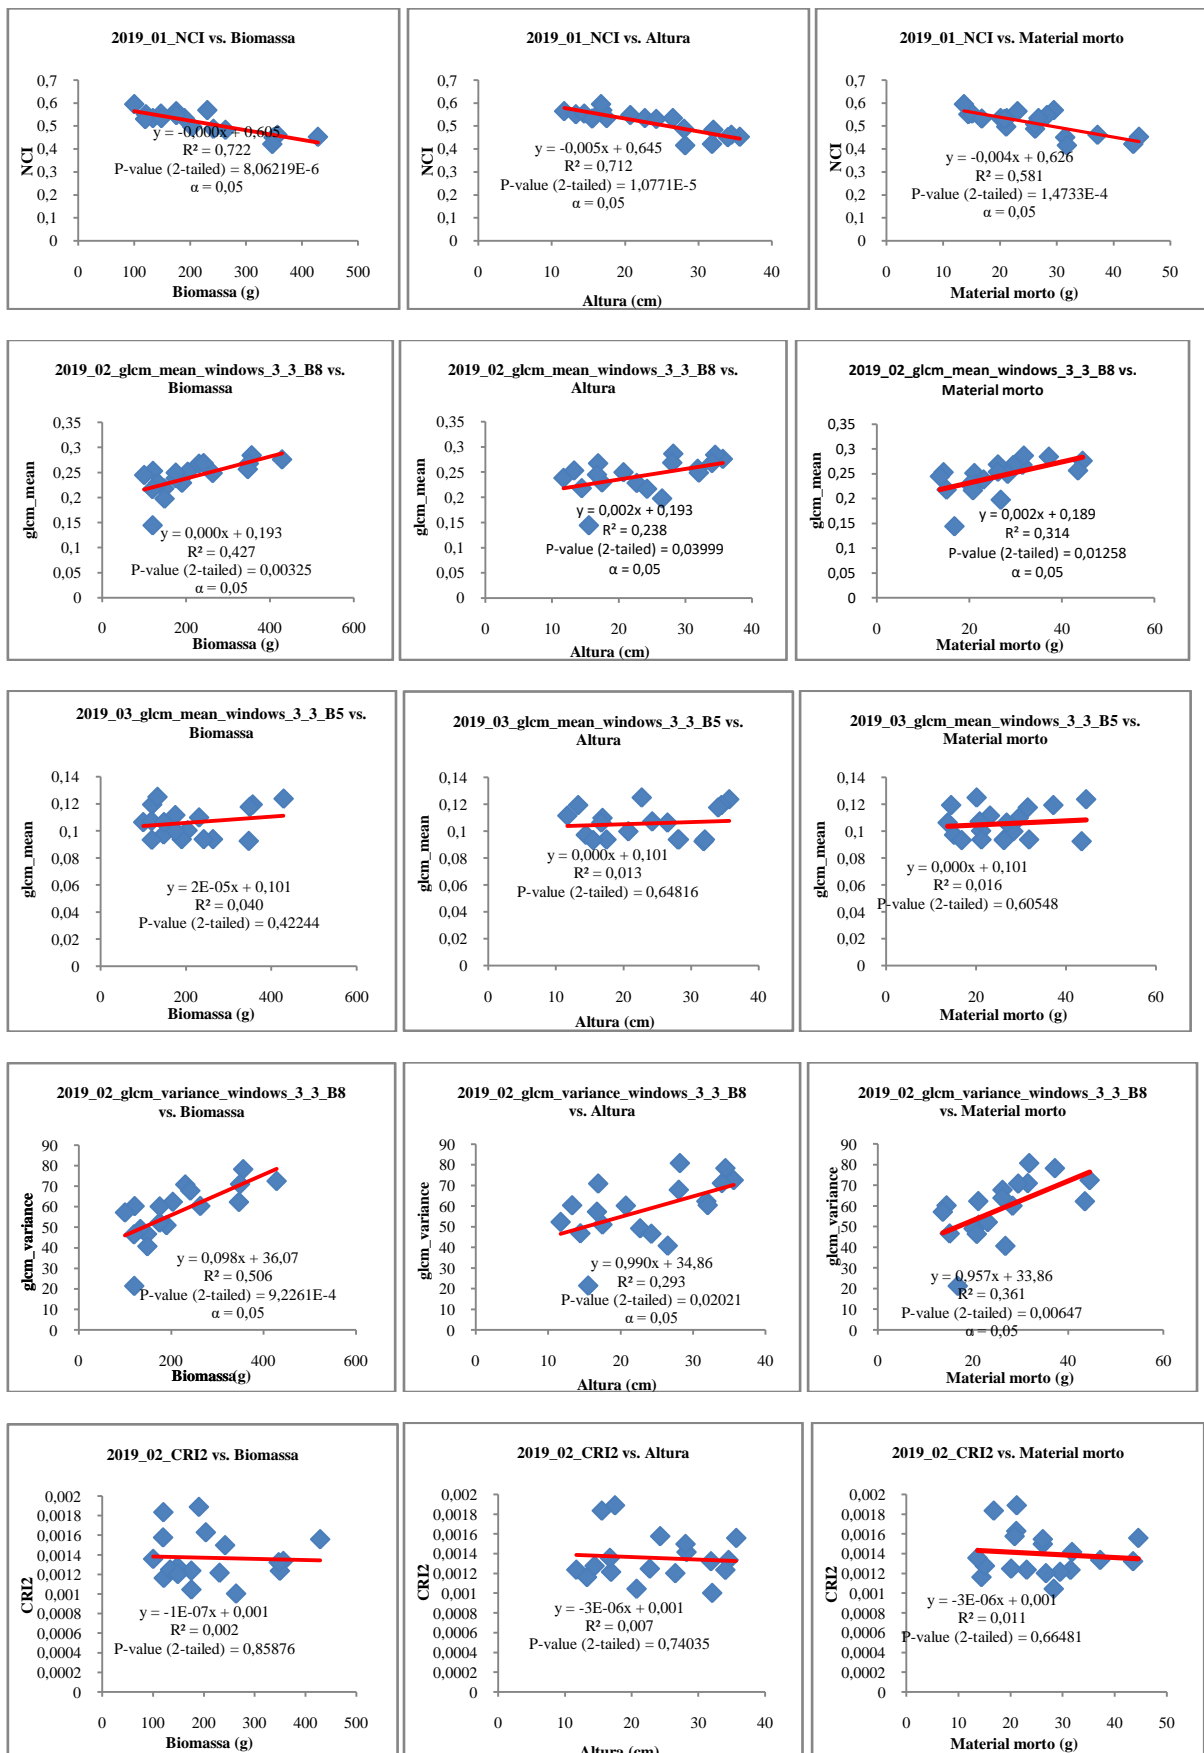
2.4.2 Correlação entre os índices de vegetação e as características biofísicas das pastagens

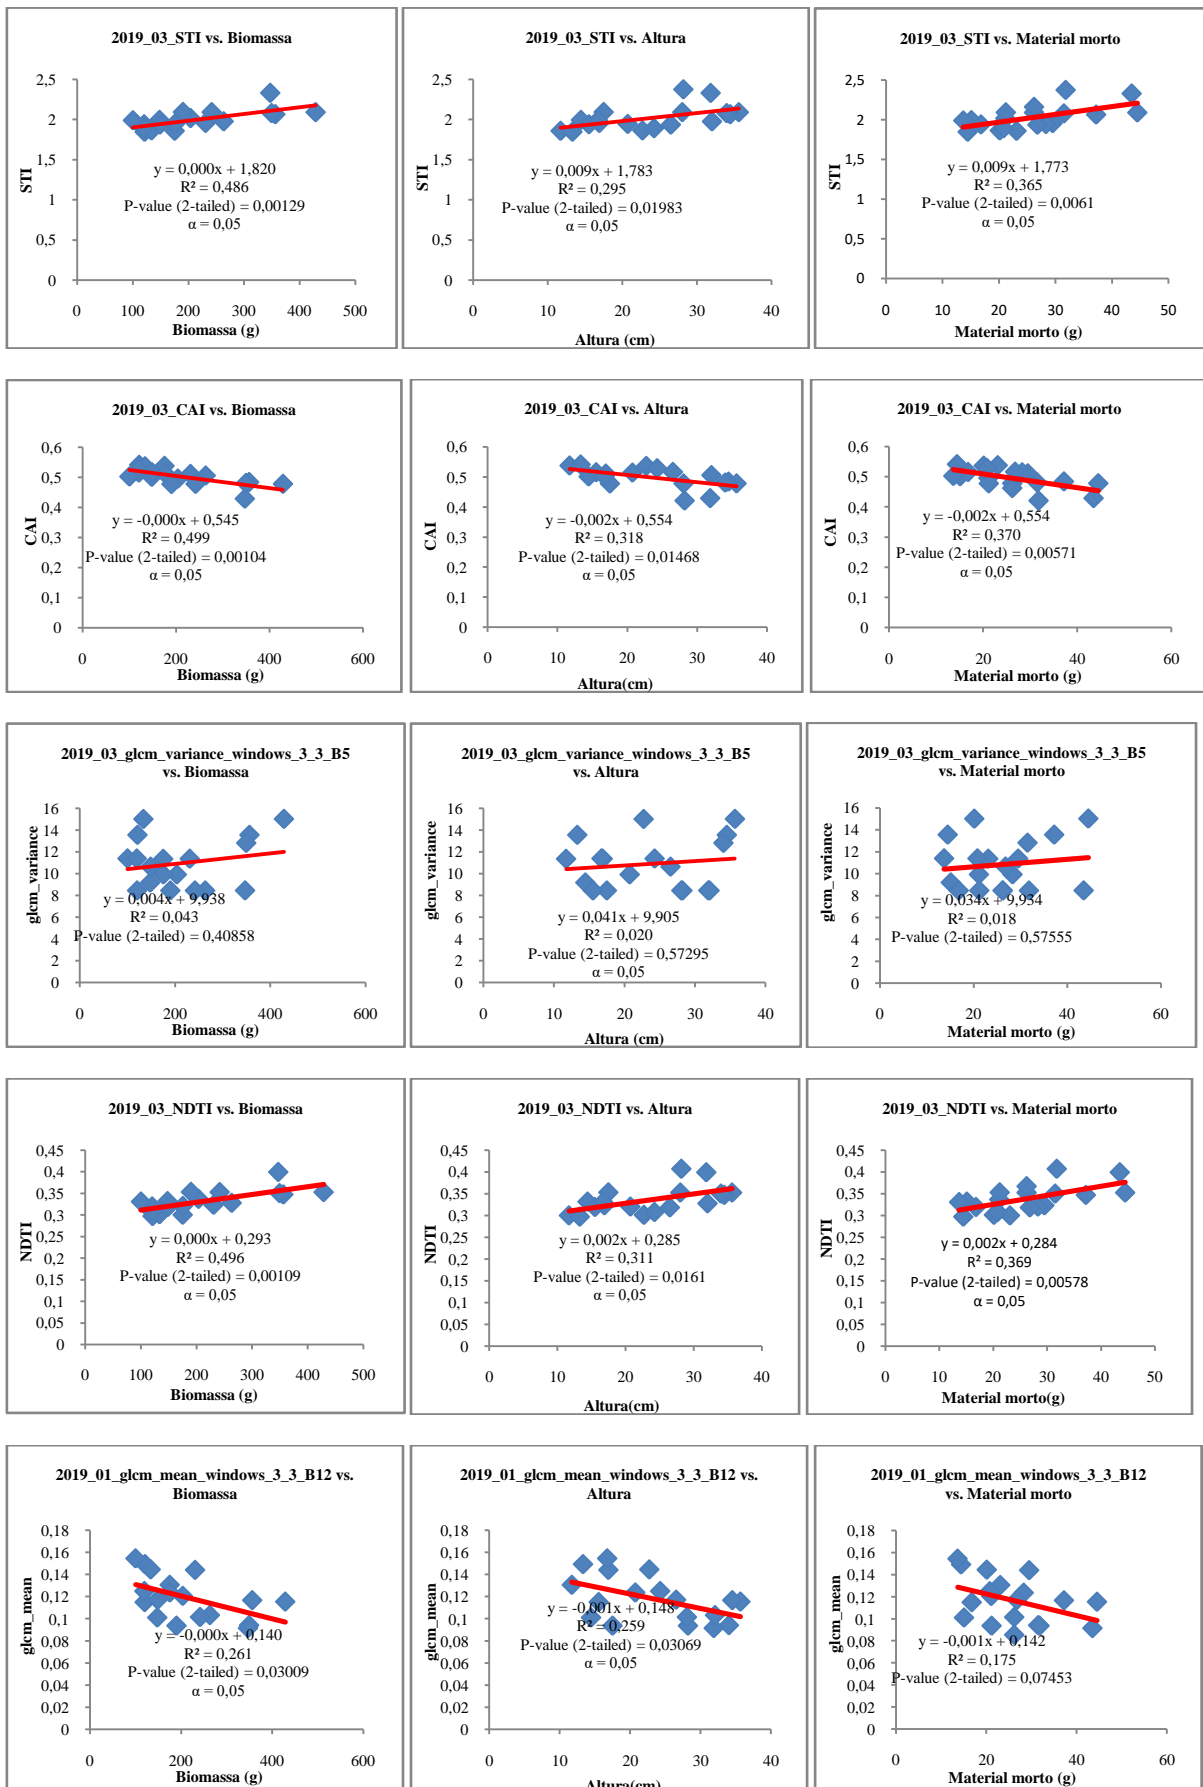
Durante a coleta das amostras de campo (*in situ*) foram selecionadas 20 regiões de controle da qualidade das pastagens, distribuídas em 5 regiões de N1, 5 regiões de N2, 5 regiões de N3 e 5 regiões de N4. Em cada uma destas regiões coletou-se biomassa das pastagens e mediu-se altura das pastagens. A biomassa das pastagens foi processada em laboratório, a partir da qual obteve-se o peso da biomassa (biomassa verde + biomassa seca) e o material morto (apenas a biomassa seca). Deste modo, obteve-se 3 características biofísicas das pastagens: peso da biomassa, altura da biomassa e o peso do material morto.

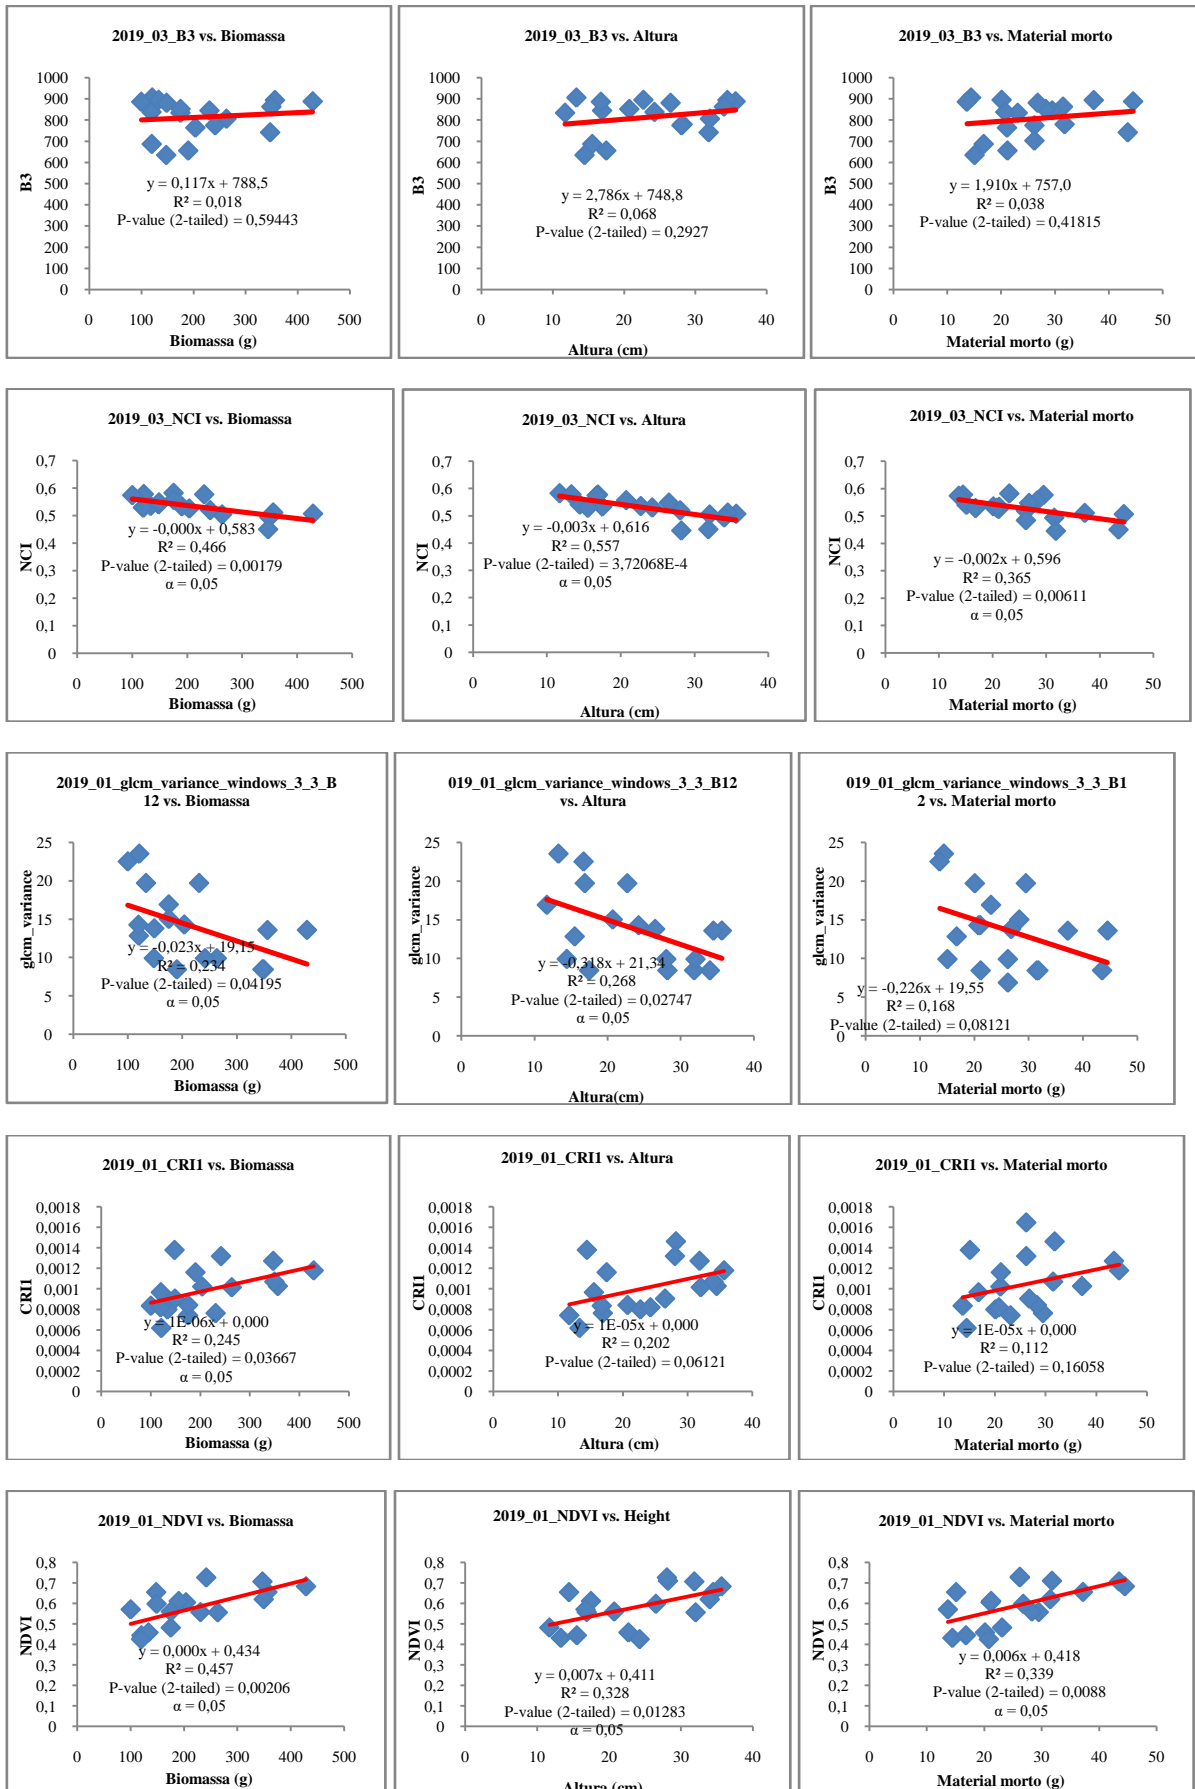
Considerando que o NCI (29/01/2019) foi a imagem (camada) mais importante no processamento digital de imagens auxiliar no R, correlacionou-se este índice com o peso da biomassa, a altura da biomassa e o peso do material morto. Alcançou-se correlação forte em 2 dos 3 casos, i.e, Biomassa e Altura, conforme a Figura 19. Na correlação NCI vs. Biomassa alcançou-se um coeficiente de Pearson $R^2 = 0.722$. Na correlação NCI vs. Altura alcançou-se um coeficiente de Pearson $R^2 = 0.712$. E na correlação NCI vs. Material Morto alcançou-se um coeficiente de Pearson $R^2 = 0.581$ (não muito bom), conforme Figura 19. O que indica que o NCI é um proxy da biomassa, refletindo desta forma o processo de degradação de pastagens, pois de todos os índices testados, o NCI foi o que apresentou maior sensibilidade ao fenômeno em análise. O NCI, além de ter tido o maior desempenho entre os diversos índices de vegetação na classificação supervisionada *random forest*, também teve a melhor correlação com os parâmetros biofísicos das pastagens coletados em campo. Deste modo, constatou-se que a biomassa (peso da biomassa = peso da biomassa verde + peso da biomassa seca) é o melhor parâmetro biofísico de caracterização do processo de degradação de pastagens.

Em função da ordem de importância na classificação supervisionada *random forest*, outros índices de vegetação e texturas GLCM também foram correlacionados com o peso da biomassa, altura e o material morto, conforme a Figura 19. Outros índices de vegetação bastante usuais como o NDVI também foram correlacionados, porém nenhum deles superou o NCI.

Figura 19 – Correlação entre alguns índices de vegetação ou texturas GLCM e características biofísicas das pastagens (biomassa, altura e material morto).







Fonte: O autor.

2.4.3 Processamento digital de imagens no *Google Earth Engine* (processamento principal)

As camadas (*layers*) usadas no *Google Earth Engine* foram as seguintes: B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12, NCI, CRI2, STI, CAI, NDTI, NDVI, VIgreen, CRI1, RGR, NDI7, REP, TVI, Transformação de Kauth-Thomas “Tasseled Cap” (brilho, verdor e umidade), Textura₁₈, GLCM, VV (SAR-Sentinel-1), VH (SAR-Sentinel-1) e Declividade (a partir do SRTM).

Assim, realizou-se os experimentos das Tabelas 2.5 e 2.6, onde se aplicou o algoritmo de classificação supervisionada *random forest* para os produtos de sensoriamento remoto supracitados. As séries temporais testadas foram definidas nos seguintes períodos: janeiro apenas, de janeiro a março (apenas na estação úmida, similar ao experimento realizado no R), de janeiro a junho, de janeiro a setembro, de janeiro a dezembro (melhor resultado), de outubro a dezembro (apenas na estação úmida novamente) e de junho a agosto (apenas na estação seca). Conforme a Tabela 7, os melhores resultados foram obtidos em 1 ano de série temporal.

As combinações de camadas (*layers*) que alcançaram os melhores resultados são apresentadas na Tabela 7 nas linhas 32 (IV*), 33 (IV* + Declividade), 34 (IV**), 35 (IV** + Declividade) e 36 (IV** + Textura₁₈), possuindo as acurácias AG = 0.94 e K = 0.91. Avaliou-se que a principal razão para que os melhores resultados sejam de 1 ano de série temporal é que o *random forest* é um algoritmo de aprendizado de máquina que aprende com o conjunto de dados. Quanto mais dados se insere no *random forest*, melhor será o aprendizado, por que o *random forest* pode compreender o comportamento temporal de cada classe e aprender as peculiaridades tanto na época úmida quanto na época seca. Por outro lado, a fenologia também é muito importante quando se trata de índices de vegetação. Desse modo, pode-se ver a produção de biomassa dos diferentes níveis de degradação de pastagens em 1 ano (2019), conforme a Figura 20 (a). Assim, o algoritmo de classificação supervisionada *random forest* pode aprender todas estas características específicas de cada classe de níveis de degradação de pastagens (N1, N2N3 e N4) e realizar uma melhor separabilidade no processo de classificação, e conseqüentemente, resultando em uma melhor acurácia estatística. A fenologia da pastagem é dada pelo NDVI.

Conforme a Figura 20 (a), as pastagens no nível N1 alcançaram o pico de crescimento em 15 de março de 2019, na estação úmida; e o vale foi alcançado em 23 de junho de 2019, na estação seca. O crescimento e diminuição da biomassa das pastagens ocorre de acordo às

condições de chuva, pode-se ver isso claramente comparando as Figura 20 (a) e Figura 20 (d). A precipitação é dada por imagens diárias de precipitação CHIRPS com resolução espacial de 5.566m por pixel. Em julho (estação seca), pode-se ver um fenômeno atípico, onde choveu na estação seca, e assim as pastagens responderam crescendo novamente. As pastagens em N1 tiveram um rápido crescimento, porque elas são vigorosas e respondem rapidamente aos eventos naturais. As pastagens em N2N3 e N4 tiveram um comportamento similar das pastagens N1 em quase todo o ano, o que significa que as pastagens foram expostas às mesmas condições climáticas, mas precisa-se prestar atenção em alguns aspectos.

Tabela 7 – Teste de acurácia com diversos produtos de sensoriamento remoto.

Séries temporais	Número de ordem	Combinações de camadas (<i>layers</i>)	Acurácia Global	Kappa
1 year (2019)	1	VV	0.87	0.80
	2	S2 + Textura ₁₈	0.89	0.84
	3	VH	0.89	0.84
	4	S2	0.90	0.85
	5	S2 + Declividade	0.90	0.85
	6	IV* + Textura ₁₈	0.92	0.87
	7	S2 + IV*	0.93	0.89
	8	S2 + IV* + Declividade	0.93	0.89
	9	S2 + IV* + Textura ₁ + VH+ Declividade	0.93	0.89
	10	S2 + IV* + Textura ₁ + VV+ Declividade	0.93	0.89
	11	S2 + IV* + Textura ₁₈	0.93	0.89
	12	S2 + IV* + Textura ₁₈ + Declividade	0.93	0.89
	13	S2 + IV* + Textura ₁₈ + VH	0.93	0.89
	14	S2 + IV* + Textura ₁₈ + VH + Declividade	0.93	0.89
	15	S2 + IV* + Textura ₁₈ + VV	0.93	0.89
	16	S2 + IV* + Textura ₁₈ + VV+ Declividade	0.93	0.89
	17	S2 + IV* + Textura ₁₈ + VV+ VH	0.93	0.89
	18	S2 + IV* + Textura ₁₈ + VV+ VH + Declividade	0.93	0.89
	19	S2 + IV* + Textura ₃ + VH+ Declividade	0.93	0.89
	20	S2 + IV* + Textura ₃ + VV+ Declividade	0.93	0.89
	21	S2 + IV** + Declividade	0.93	0.89
	22	S2 + IV** + Textura ₁ + VH+ Declividade	0.93	0.89
	23	S2 + IV** + Textura ₁ + VV+ Declividade	0.93	0.89
	24	S2 + IV** + Textura ₁₈ + VH + Declividade	0.93	0.89
	25	S2 + IV** + Textura ₁₈ + VV+ Declividade	0.93	0.89
	26	S2 + IV** + Textura ₁₈ + VV+ VH	0.93	0.89
	27	S2 + IV** + Textura ₁₈ + VV+ VH + Declividade	0.93	0.89
	28	S2 + IV** + Textura ₃ + VH+ Declividade	0.93	0.89
	29	S2 + IV** + Textura ₃ + VV+ Declividade	0.93	0.89
	30	S2 + IV** + Textura ₈ + VH+ Declividade	0.93	0.89
	31	S2 + IV** + Textura ₈ + VV+ Declividade	0.93	0.89
	32	IV*	0.94	0.91
	33	IV* + Declividade	0.94	0.91
	34	IV**	0.94	0.91
	35	IV** + Declividade	0.94	0.91
	36	IV** + Textura ₁₈	0.94	0.91

Legenda: (S2) Sentinel-2; (VH) Polarização Vertical-Horizontal de imagens SAR; (VV) Polarização Vertical-Vertical de imagens SAR; (Textura) texturas GLCM; (Declividade) Declividade calculada a partir do SRTM; (IV*) Nos Índices de Vegetação, quando a Tasseled Cap é apenas brilho e verdor; (IV**) Nos Índices de Vegetação, quando a “Tasseled Cap” está completa, i.e., brilho, verdor e umidade.

Fonte: O autor.

Na Tabela 8, para controlar a qualidade da separabilidade dos níveis de degradação das pastagens, apresenta-se as acurácias da classificação supervisionada *random forest* (Acurácia Global, *Kappa* e *F-score*) usando bandas puras Sentinel-2, Índices de Vegetação, Texturas, imagens SAR-Sentinel-1 e Declividade (S2 + IV** + Textura₁₈ + VH+ Declividade).

Tabela 8 – Controle da acurácia da classificação *random forest* com base em (S2 + IV** + Textura₁₈ + VH+ Declividade).

Série temporal	Nível de Degradação	Acurácia do Produtor	Acurácia do Usuário	<i>F-score</i>	Acurácia Global	<i>Kappa</i>
1 mês (Jan)	N1	0.91	0.91	0.91	0.84	0.75
	N2N3	0.86	0.82	0.84		
	N4	0.74	0.80	0.76		
3 meses (Jan – Mar) OBS.: Apenas na estação úmida.	N1	0.91	0.91	0.91	0.86	0.78
	N2N3	0.89	0.85	0.87		
	N4	0.77	0.84	0.80		
6 meses (Jan – Jun)	N1	0.95	0.95	0.95	0.92	0.87
	N2N3	0.97	0.88	0.92		
	N4	0.81	0.95	0.88		
9 meses (Jan – Set)	N1	1	0.95	0.97	0.93	0.89
	N2N3	0.97	0.90	0.93		
	N4	0.81	0.95	0.88		
1 ano (Jan – Dez) OBS.: Os melhores resultados.	N1	1	0.95	0.97	0.93	0.89
	N2N3	0.97	0.90	0.93		
	N4	0.81	0.95	0.88		
3 meses (Out – Dez) OBS.: Apenas na estação úmida.	N1	0.86	0.86	0.86	0.86	0.78
	N2N3	0.92	0.81	0.87		
	N4	0.74	0.95	0.83		
3 meses (Jun – Ago) OBS.: Apenas na estação seca.	N1	1	0.92	0.95	0.96	0.94
	N2N3	0.97	0.97	0.97		
	N4	0.92	1	0.96		

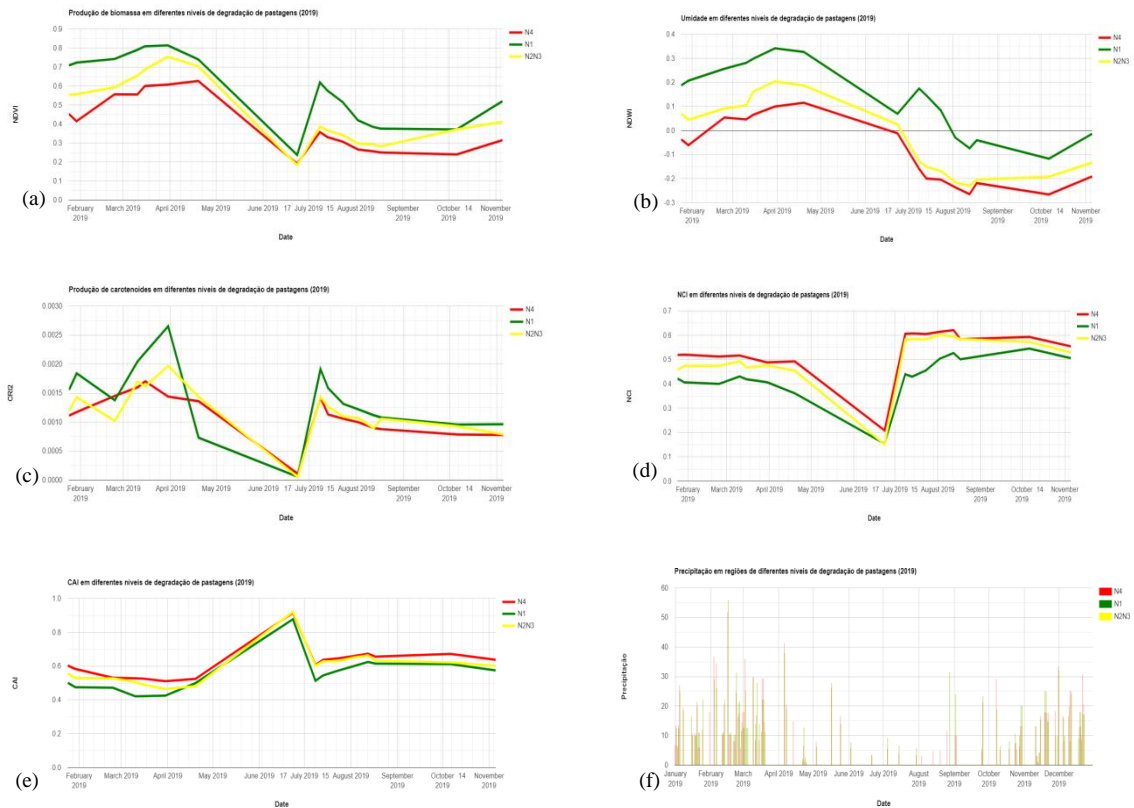
Legenda: (S2) Sentinel-2; (VH) Polarização Vertical-Horizontal de imagens SAR; (Textura) texturas GLCM; (Declividade) Declividade calculada a partir do SRTM; (IV**) Nos Índices de Vegetação, quando a “Tasseled Cap” está completa, i.e., brilho, verdor e umidade.

Fonte: O autor.

Primeiramente, de acordo com a Figura 7 (a), pode-se observar o comportamento esperado com a curva de biomassa N1 no topo, logo abaixo a curva de biomassa N2N3, e mais abaixo a curva de biomassa N4. Em segundo lugar, as condições de umidade das pastagens são dadas pelo NDWI e o comportamento foi o esperado, ou seja, pastagens mais vigorosas apresentaram valores mais altos de NDWI e pastagens menos vigorosas apresentaram valores mais baixos de NDWI, conforme a Figura 7 (b). A curva do NDWI é muito similar à curva do NDVI, ambas são influenciadas pelo ciclo das chuvas. Em terceiro lugar, observou-se que em 23 de junho (vale), todas as curvas das pastagens estão muito próximas nos cinco (5) gráficos (NDVI, NDWI, CRI2, NCI e CAI), o que significa que as suas respostas espectrais são bastante similares quando as chuvas estão se escasseando. Em quarto lugar, observou-se que as pastagens N1 têm um forte crescimento comparando com

N2N3 e N4 em 8 de julho de 2019, conforme a Figura 20 (a). Esta peculiaridade (chuva na estação seca) pode explicar o porquê que se obteve bons resultados na estação seca, conforme a Tabela 8. Em quinto lugar, o conteúdo de carotenoides é dado pelo índice de vegetação CRI2. A Figura 20 (c) apresenta a produção de carotenoides em diferentes níveis de degradação de pastagens (N1, N2N3 e N4) em 1 ano (2019). Assim, observou-se que na estação úmida as pastagens mais vigorosas têm uma forte produção de carotenoides, mas as pastagens em degradação (N2N3 e N4) têm uma produção moderada de carotenoides nas mesmas condições climáticas. Observou-se também que as pastagens mais vigorosas tiveram uma diminuição mais rápida da produção de carotenoides quando as chuvas estavam se escasseando, mas as pastagens em processo de degradação (N2N3 e N4) tiveram diminuição mais lenta da produção de carotenoides nas mesmas condições climáticas, conforme Figura 20(a) e Figura 20 (d). Portanto, como já foi explicado na seção 2.2.2 sobre as características dos carotenoides, quando as plantas estão em senescência ou têm algum estresse, reduzem a produção de clorofila e retêm os carotenoides como um mecanismo de defesa à exposição da luz (GITELSON et al., 2002; MERZLYAK; GITELSON, 1995). Contudo, pastagens em processo de degradação são mais estáveis quanto às condições climáticas, e pastagens mais saudáveis respondem melhor aos estímulos (condições climáticas), porque possuem um sistema de radicular bem desenvolvido, permitindo a produção de folhas, a manutenção e o crescimento saudável, bem como ser resistente às condições climáticas. Tanto na estação úmida quanto na estação seca, pode-se ver um comportamento mais estabilizado das pastagens nos níveis N2N3 e N4 quando se trata de produção de carotenoides. Em sexto lugar, na Figura 20 (d), pode-se observar o comportamento do índice de vegetação mais importante (NCI) em diferentes níveis de degradação de pastagens ao longo do ano 2019. As pastagens no nível de degradação N4 apresentam os maiores valores de NCI, seguidas das pastagens no nível de degradação N2N3, e posteriormente as pastagens no nível de degradação N1 com os valores de NCI mais baixos. Assim, quanto mais degradada a pastagem maior o valor de NCI. O NCI por si só não é capaz de garantir uma separabilidade satisfatória das classes N1, N2N3 e N4. Portanto, foi necessário adicionar outros índices de vegetação, texturas e imagens SAR para obter bons resultados, conforme Tabela 7. E finalmente, na Figura 20 (e), pode-se observar o comportamento da curva CAI ao longo do ano 2019, alcançando o pico no auge da estação seca, quando as pastagens estão produzindo celulose e lignina.

Figura 20 – Perfis temporais para a avaliação do comportamento das pastagens nos diferentes níveis de degradação (N1, N2N3 e N4).



Legenda: (a) NDVI: Produção de biomassa das pastagens ao longo do ano 2019 nas estações úmida e seca. (b) NDWI: Condições de umidade das pastagens ao longo do ano 2019. (c) NCI: Curva de comportamento do índice de vegetação mais importante das pastagens nos diferentes níveis de degradação ao longo do ano 2019. (d) CAI: Índice de Absorção da Celulose das pastagens ao longo do ano 2019. (f) CHIRPS: Ciclo das chuvas de janeiro a dezembro de 2019 sobre pastagens em diferentes níveis de degradação, mostrando que estas pastagens estiveram submetidas às mesmas condições de precipitação.

Fonte: O autor.

A área de estudo tem forte influência de relevo, conforme Figura 16, e as camadas de declividade e elevação podem comprovar esse fato, conforme Figura 21 (a) e Figura 21 (b).

As imagens SAR por si só tiveram uma performance satisfatória na separabilidade dos níveis de degradação das pastagens de acordo com as acurácias obtidas, conforme Tabela 7, isto é, VV (AG = 0.87 e K = 0.80) e VH (AG = 0.89 e K = 0.84). Nas combinações de diversos produtos de sensoriamento remoto, conforme Tabela 7, as imagens SAR-Sentinel-1 e a Declividade não proporcionaram melhorias significativas nas acurácias dos resultados finais, provavelmente porque os índices de vegetação tiveram um desempenho bastante satisfatório. Embora o sinal do radar seja uma função de rugosidade (relevo) e de umidade (conteúdo de água das pastagens), e em Valença/RJ existem características de relevo acentuado, além de considerar as condições de conteúdo de água das pastagens (quanto mais

saudável mais conteúdo de água), mesmo assim as imagens de radar não melhoraram as acurácias dos resultados finais, conforme Tabela 7. O modelo tridimensional apresentado na Figura 16 permite observar com clareza as características do relevo na área de estudo. A área de estudo é uma região cuja configuração do relevo é bastante variável, sendo plana em determinadas regiões e em outras bastante irregular, com existência de várias montanhas.


As séries temporais de 1 ano apresentaram os melhores resultados nas combinações da Tabela 7. Para análise, selecionou-se o caso (S2 + IV** + Textura₁₈ + VH+ Declividade), onde foram usados diversos produtos de sensoriamento remoto e alcançou-se as acurácias AG = 0.93, K = 0.89 e *F-score* (N1 = 0.97; N2N3 = 0.93; N4 = 0.88), sendo consideradas bastante relevantes e significativas. A acurácia do usuário de N1 = 0.95, N2N3 = 0.90 e N4 = 0.95, significa que para um usuário que deseja usar o mapa gerado existe uma probabilidade de 95% de selecionar acertadamente um pixel N1, uma probabilidade de 90% de selecionar acertadamente um pixel N2N3 e uma probabilidade de 95% de selecionar um pixel N4, com uma resolução espacial de 20m. Porém, quanto mais dados de campo estiverem disponíveis para testar e aperfeiçoar esta metodologia será uma mais-valia.

As áreas correspondentes aos níveis de degradação de pastagens foram calculadas, conforme a Figura 23, obtendo-se os seguintes valores: N1 = 21.333,629ha, N2N3 = 34.537,939ha e N4 = 9.641,280ha. O que demonstra que na área de estudo existe uma maior ocorrência de pastagens em nível de degradação moderada (52.72%), seguida de pastagens em bom estado de conservação (32.56%), e finalmente pastagens muito degradadas (14.72%). Na Figura 22, apresenta-se o mapa dos níveis de degradação das pastagens da área de estudo usando a seguinte combinação dos produtos de sensoriamento remoto: S2 + IV** + Textura₁₈ + VH+ Declividade.

Finalmente, as metodologias (Tabela 7) se mostraram robustas, eficientes e eficazes para o objetivo proposto de separabilidade dos diferentes níveis de degradação de pastagens por meio de técnicas de Sensoriamento Remoto.

No total, no *Google Earth Engine*, processou-se 1.175 camadas para obter os resultados deste trabalho, além de 364 imagens de precipitação para complementar a análise gráfica, totalizando 1.539 imagens.


Figura 21 – Informação do relevo em 3 regiões com diferentes níveis de degradação de pastagens.



Legenda: (a) Declividade. (b) Elevação.


Fonte: O autor.

Figura 22 – Mapa dos níveis de degradação de pastagens da área de estudo baseado em: S2 + IV** + Textura₁₈ + VH+ Declividade.



Fonte: O autor.

Figura 23 – Estatísticas das áreas (ha) dos níveis de degradação de pastagens baseadas em: S2 + IV** + Textura₁₈ + VH+ Declividade.



Fonte: O autor.

2.5 Conclusões

Para as condições estudadas relativamente aos níveis de degradação das pastagens chegou-se as seguintes conclusões:

- O NCI foi o índice de vegetação mais importante na separabilidade dos níveis de degradação de pastagens N1, N2N3 e N4, mas isoladamente não foi capaz de garantir uma separabilidade satisfatória, alcançando apenas as acurácias AG = 0.61 e K= 0.39. Então, foi necessário adicionar outros índices de vegetação, texturas e imagens SAR para se obter melhores resultados.
- Na correlação entre os índices de vegetação e as características biofísicas das pastagens, a biomassa (peso da biomassa = peso da biomassa

verde + peso da biomassa seca) foi a característica biofísica das pastagens mais importante, tendo a melhor correlação com o NCI ($R^2 = 0.722$). No entanto, a altura das pastagens também teve uma forte correlação com o NCI ($R^2 = 0.712$). Apenas o peso do material morto teve uma correlação fraca com o NCI ($R^2 = 0.581$).

- As metodologias propostas permitiram alcançar resultados bastante satisfatórios para a separabilidade dos níveis de degradação das pastagens N1, N2N3 e N4, onde os melhores resultados alcançados foram AG = 0.94 e K = 0.91, conforme Tabela 7.
- O caso S2 + IV** + Textura₁₈ + VH+ Declividade é uma combinação de diferentes produtos de sensoriamento remoto e foi usado para gerar o mapa dos níveis de degradação das pastagens com as suas respectivas acurácias (AG = 0.93; K = 0.89) e estatísticas (L1 = 21.333,629ha; L2L3 = 34.537,939ha; L4 = 9.641,280ha), o que significa que os resultados são satisfatórios.
- Este estudo demonstrou que apenas usando uma série temporal de 1 ano de imagens Sentinel-2 (S2) com as bandas B2, B3, B4, B5, B6, B7, B8, B8A, B11 e B12, já é possível obter resultados satisfatórios com as acurácias AG = 0.92 e K = 0.87.
- Este estudo também demonstrou que séries temporais de 1 ano de imagens SAR-Sentinel-1 nas polarizações VV e VH também garantem resultados satisfatórios (Tabela 7), obtendo-se as acurácias (AG = 0.87 K = 0.80) e (AG = 0.89; K = 0.84), respectivamente.
- As polarizações VV (AG = 0.87 K = 0.80) e VH (AG = 0.89; K = 0.84) do SAR-Sentinel-1 tiveram um desempenho satisfatório, mas não melhoraram os resultados das acurácias ao serem combinados com outras camadas (*layers*), provavelmente porque os índices de vegetação (IV* e IV**) tiveram um desempenho bastante satisfatório (AG = 0.94; K = 0.91).
- A combinação do R e *Google Earth Engine* foi muito positiva, pois o R, a partir do conjunto de camadas de entrada (Tabela 5), indicou a ordem de importância das mesmas; e o *Google Earth Engine* processou rapidamente a série temporal das camadas mais importantes indicadas pelo R.
- Observou-se que algoritmos de aprendizado de máquina, como o *random forest*, aprendem melhor quanto maior for a quantidade de

informações. Por isso, nas metodologias propostas, séries temporais de 1 ano mostraram-se mais eficientes do que apenas 3 meses de imagens de satélites na separabilidade dos níveis de degradação das pastagens.

- Por fim, as metodologias propostas (Tabela 7) se mostraram ser robustas, eficientes e eficazes para o objetivo proposto de separabilidade dos níveis de degradação de pastagens por meio de técnicas de Sensoriamento Remoto e Processamento Digital de Imagens.

3 AVALIAÇÃO DOS NÍVEIS DE DEGRADAÇÃO DAS PASTAGENS DO CERRADO, BRASIL. UMA ABORDAGEM DE SENSORIAMENTO REMOTO USANDO SÉRIES TEMPORAIS DE IMAGENS SENTINEL-2, RANDOM FOREST E GOOGLE EARTH ENGINE

Resumo

O presente estudo teve como objetivo desenvolver uma metodologia baseada em técnicas de Sensoriamento Remoto e Processamento Digital de Imagens de satélite Sentinel-2 para o monitoramento, mapeamento e avaliação da qualidade das pastagens de todo o bioma Cerrado. Dessa forma, de acordo com a literatura, os níveis de degradação das pastagens foram definidos como N1, N2N3 e N4, desde as pastagens mais vigorosas até as mais degradadas. O Cerrado possui uma área superficial de 2.036.448 km², o que corresponde a 24% do território brasileiro, sendo um dos 6 biomas do país. Para a identificação dos diferentes níveis de degradação de pastagens do Cerrado foram usados 4.212 pontos georreferenciados nos níveis de degradação N1, N2N3 e N4. Usou-se imagens Sentinel-2, pontos de campo, criou-se uma máscara de ocorrência das pastagens a partir do mapa de Uso e Cobertura da Terra versão 6 do MapBiomas que é indicada pelo valor de pixel 15; e, finalmente, processou-se este conjunto de dados no algoritmo de classificação *Random Forest*. O processamento das imagens digitais foi realizado no *Google Earth Engine*. A classificação *random forest* revelou que no bioma Cerrado tem-se: N1 (57%), N2N3 (27%) e N4 (16%); e as precisões foram: Acurácia Global = 0,94; Kappa = 0,91; e F-score (N1 = 0,94, N2N3 = 0,94, N4 = 0,94). Finalmente, sob as condições estudadas, a metodologia proposta neste estudo provou ser robusta, eficiente e eficaz para o objetivo proposto da separabilidade dos níveis de degradação de pastagens por meio de técnicas de Sensoriamento Remoto e Processamento Digital de Imagens de satélite Sentinel-2.

3.1 Introdução

A superfície territorial do Brasil é de 8.510.345,538 km² (IBGE, 2021c). O país possui 6 biomas, nomeadamente: Amazônia (49%), Caatinga (10%), Cerrado (24%), Mata Atlântica (13%), Pampa (2%) e Pantanal (2%), com as suas correspondentes proporções de áreas do território brasileiro (IBGE, 2022a). O bioma Cerrado compreende uma área superficial de 2.036.448 km² (IBGE, 2022b) e abrange os estados da Bahia (BA; 27%), Distrito Federal (DF; 100%), Goiás (GO; 97%), Maranhão (MA; 65%), Mato Grosso (MT; 39%), Mato Grosso do Sul (MS; 61%), Minas Gerais (MG; 57%), Paraná (PR; 2%), Piauí (PI; 37%), Rondônia (RO; 1%), São Paulo (SP; 32%), Tocantins (TO; 91%), além de áreas disjuntas de Cerrado nos estados do Amapá (AP), Amazonas (AM), Pará (PA) e Roraima (RR), as percentagens correspondem à proporção do Cerrado em cada estado (EMBRAPA, 2022; IBGE, 2022b). O Cerrado é o bioma com a maior produção agropecuária do Brasil, contribuindo com 55% da produção de carne do país (EMBRAPA, 2014a). Até o ano de 2020, o Cerrado possuía uma área de pastagens de cerca de 48.160.607 ha (MAPBIOMAS, 2021). Segundo um estudo da Embrapa, mais de metade das pastagens do Cerrado podem se encontrar em algum estágio de degradação (EMBRAPA, 2014a). O mesmo estudo indica que a recuperação das pastagens poderia triplicar a produção de carne no Cerrado ou promover a expansão da agricultura, além de mitigar as emissões de gases de efeito estufa (EMBRAPA, 2014a). Em 2020, o Brasil teve um PIB de R\$ 7,45 trilhões (CNA, 2022a), o agronegócio contribuiu com 27% do PIB do Brasil (R\$ 1,98 trilhões), sendo 70% (R\$ 1,38 trilhões) proveniente do setor agrícola e 30% (R\$ 602,3 bilhões) oriundo do setor da pecuária (CNA, 2022b).

Nos últimos 40 anos, o Brasil tem vivenciado uma profunda revolução agrícola que já é considerada o marco econômico mais significativo na história recente do país, além de possibilitar a projeção de um cenário de desenvolvimento futuro para o país (CNA, 2022b). Neste período de 40 anos, o Brasil passou de importador para um importante celeiro do mundo (GOMES et al., 2016). O Cerrado permaneceu inalterado até década de 1950, as grandes transformações tiveram início na década de 1960, com a transferência da capital federal do Rio de Janeiro para Brasília, além da abertura de novas estradas, bem como a pecuária e a agricultura intensiva (IBGE, 2022a).

A degradação de pastagens é um grande empecilho ao setor da pecuária brasileira, e ademais, as iniciativas de recuperação das pastagens têm encontrado inúmeras dificuldades na

sua implementação, devido principalmente à falta de informação atualizada e detalhada relativamente a localização das áreas de pastagens degradadas (EMBRAPA, 2014a). A recuperação de pastagens proporciona a redução da pressão na abertura de novas fronteiras agrícolas para a expansão da agricultura e pecuária em áreas de floresta nativa (ARAGÃO et al., 2020). Em pastos recuperados, além de se alcançar maior produtividade, há também menor emissão de gases de efeito estufa por animal, o que aumenta a rentabilidade econômica da pecuária e a torna ecologicamente mais sustentável (ARAGÃO et al., 2020). O Governo do Brasil tem investido na intensificação dos sistemas produtivos, além de orientar o uso sustentável dos recursos naturais com base em zoneamentos agroecológicos e programas de mitigação e controle de desmatamento (GOMES et al., 2016). Vale aqui ressaltar o Programa de Agricultura de Baixo Carbono (ABC), o Novo Código Florestal, a Política Nacional de Biossegurança e o Cadastro Ambiental Rural (GOMES et al., 2016).

Cada bioma tem as suas próprias características de degradação das pastagens. As principais características da degradação das pastagens no Cerrado são a perda de produtividade devido a baixa oferta de água e de nutrientes (ARAGÃO et al., 2020).

O sensoriamento remoto se apresenta como a ferramenta ideal para a identificação, monitoramento e mapeamento do processo de degradação de pastagens no Cerrado, e no Brasil como um todo, apoiando políticas públicas como o Programa Agricultura de Baixo Carbono (ABC) do governo federal, em que uma das linhas é justamente a recuperação das pastagens degradadas (ARAGÃO et al., 2020; EMBRAPA, 2014a).

Nesta pesquisa, aplicou-se com sucesso o sensoriamento remoto no monitoramento e mapeamento da qualidade das pastagens em todo o bioma Cerrado, dada a sua importância para a pecuária brasileira. A metodologia proposta no presente estudo, desenvolvida em grande parte no capítulo anterior (uma parcela do bioma Mata Atlântica), aqui é ajustada para se adaptar às características edafoclimáticas e vegetacionais do bioma Cerrado, bem como se adaptar também ao processamento de grandes volumes de dados (imagens de satélite e pontos georreferenciados coletados em campo), proporcionais às grandes extensões territoriais do bioma Cerrado. Para tal, recorreu-se ao uso do *Google Earth Engine*, que se constitui em uma poderosa ferramenta de processamento digital de imagens de satélite e de informação georreferenciada. Em seu ambiente computacional, o *Google Earth Engine* reúne ferramentas de sensoriamento remoto, inteligência artificial, computação paralela e computação em nuvem. No *Google Earth Engine* elaborou-se um código de programação em linguagem *JavaScript*, cujo método de classificação de imagens selecionado foi o algoritmo de aprendizado de máquina denominado *Random Forest* que tem sido bastante robusto e

eficiente em diversas aplicações (BREIMAN, 2001; BREIMAN; CUTLER, 2014; JENSEN, 2016). A classificação *random forest* resultou em um mapa de classificação das pastagens degradadas do Cerrado em três (3) níveis de degradação (N1, N2N3 e N4), com base nos quatro (4) níveis de degradação (N1, N2, N3 e N4) descritos na literatura (DIAS-FILHO, 2015). Finalmente, todos os dados produzidos foram tratados em ambiente SIG para a extração e exibição da informação geográfica quantitativa e qualitativa relativa às pastagens degradadas do bioma Cerrado.

3.2 Metodologia

3.2.1 Área de estudo

Na presente pesquisa, a área de estudo corresponde a todo o bioma Cerrado com uma área superficial de 2.036.448 km² (IBGE, 2022b). O bioma Cerrado abrange os estados da Bahia (BA), Distrito Federal (DF), Goiás (GO), Maranhão (MA), Mato Grosso (MT), Mato Grosso do Sul (MS), Minas Gerais (MG), Paraná (PR), Piauí (PI), Rondônia (RO), São Paulo (SP), Tocantins (TO), além de áreas disjuntas de Cerrado nos estados do Amapá (AP), Amazonas (AM), Pará (PA) e Roraima (RR) (EMBRAPA, 2022; IBGE, 2022b). Até o ano de 2020, a área de pastagens do Cerrado era de 48.160.607 ha (MAPBIOMAS, 2021).

As pastagens foram classificadas em N1, N2N3 e N4 (Figura 24), de acordo aos parâmetros definidos por Dias-Filho (2015), conforme a Tabela 9.

Inicialmente, foram coletados 400 pontos em campo (cortesia do Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás - LAFIG), e com o auxílio do Google Earth, Sistemas de Informação Geográfica (ArcGIS e QGIS) e de técnicas de fotointerpretação, estes pontos foram multiplicados para um total de 4.212, conforme a Tabela 10.

Figura 24 – Níveis das pastagens degradadas.



Legenda: (a) N1 (época úmida). (b) N1 (época seca). (c) N2N3 (época úmida). (d) N2N3 (época seca). (e) N4 (época úmida). (f) N4 (época seca).

Fonte: Cortesia do Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás – LAPIG.

Fonte: O autor.

Tabela 9 – Estádios de Degradação (ED) de pastagens segundo Parâmetros Limitantes, indicadores de Queda na Capacidade de Suporte (QCS), e Nível de Degradação (Nível).

ED	Parâmetro Limitante	QCS (%)	Nível
1	Vigor e solo descoberto	Até 20	Leve (N1)
2	Estádio 1 agravado + plantas invasoras	21 - 50	Moderado (N2)
3	Estádio 2 agravado ou morte das forrageiras (degradação agrícola)	51 - 80	Forte (N3)
4	Solo descoberto + erosão (degradação biológica)	> 80	Muito forte (N4)

Fonte: Adaptado de DIAS-FILHO, 2015.

Tabela 10 – Informação das amostras de campo.

Nível de Degradação	Nº de pontos de campo	Total	Data de aquisição
N1	1.404		03/2019
N2N3	1.404	4.212	05/2019
N4	1.404		08/2019

Fonte: O autor.

Tabela 11 – Índices de Vegetação para o Sentinel-2.

Índice de Vegetação	Fórmula equivalente Sentinel-2	Referências
Cellulose Absorption Index (CAI)	$B7/B6$	(GUERSCHMAN et al., 2009; HILL, 2013)
Carotenoid Reflectance Index 1 (CRI1)	$(1/B2) - (1/B3)$	(GITELSON et al., 2002; HILL, 2013)
Carotenoid Reflectance Index 2 (CRI2)	$(1/B2) - (1/B5)$	(GITELSON et al., 2002)
Green Vegetation Index (VIgreen)	$(B3 - B4)/(B3 + B4)$	(DAUGHTRY et al., 2005; PEÑA-BARRAGÁN et al., 2011).
Normalized Canopy Index (NCI)	$(B6 - B3)/(B6 + B3)$	(LI; GUO, 2016; REN; ZHOU, 2019)
Normalized Difference Index (NDI7)	$(B5 - B7)/(B5 + B7)$	(DINGAAN; TSUBO, 2019; LI; GUO, 2016)
Normalized Difference Tillage Index (NDTI)	$(B6 - B7)/(B6 + B7)$	(DINGAAN; TSUBO, 2019; LI; GUO, 2016; VAN DEVENTER et al., 1997)
Normalized Difference Vegetation Index (NDVI)	$(B5 - B4)/(B5 + B4)$	(HUETE et al., 2002; ROUSE et al., 1973)
Red Edge Position (REP)	$700 + 40(B_{red\ edge} - B5)/(B6 - B5)$	(CLEVERS, 1994)
Red-Green Ration (RGR)	$B_{red\ edge} = (B4 + B7)/2$ $B4/B3$	(HILL, 2013; SIMS; GAMON, 2002)
Soil Tillage Index (STI)	$B6/B7$	(DINGAAN; TSUBO, 2019)
Triangular Vegetation Index (TVI)	$0.5((120(B8 - B3)) - 200(B4 - B3))$	(BROGE; LEBLANC, 2001; PEÑA-BARRAGÁN et al., 2011)

Fonte: O autor.

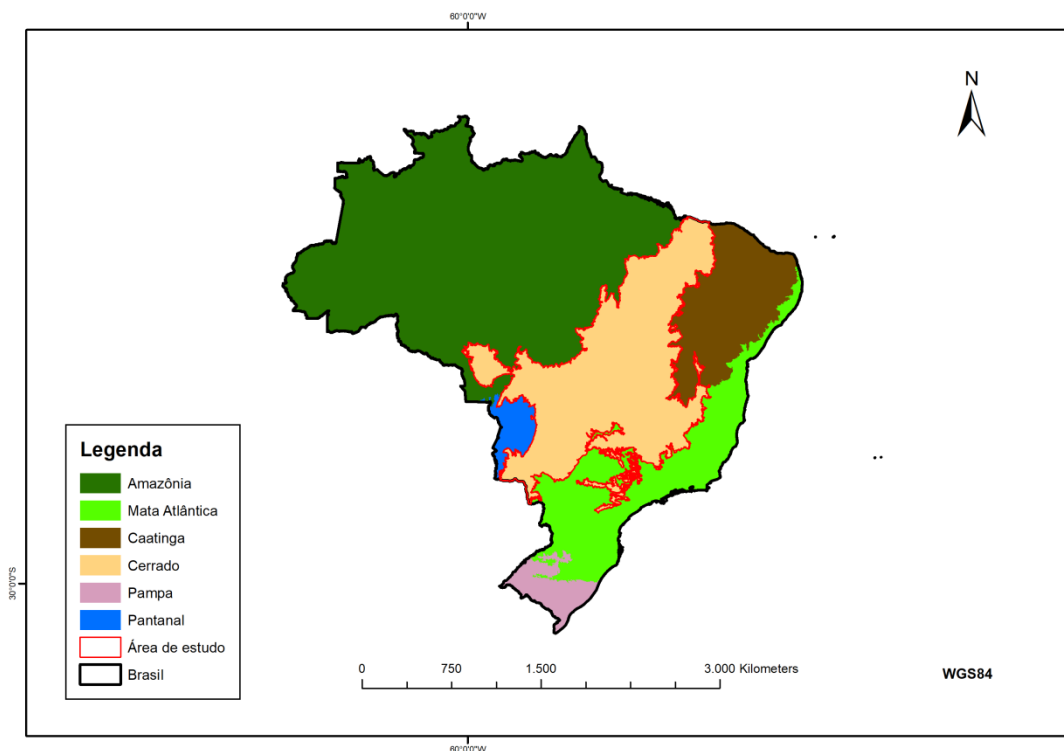
3.2.2 Materiais

Para a preparação da presente pesquisa, os seguintes materiais foram necessários:

- Dados vetoriais (formato shapefile) do Brasil e do Cerrado (IBGE, 2021b);
- 4.212 pontos georreferenciados de pastagens degradadas nos níveis N1, N2N3 e N4 do bioma Cerrado. Os trabalhos de campo foram realizados nos meses de março, maio e agosto de 2019;
- Softwares: QGIS 3 e ArcGIS 10, para a produção de mapas e multiplicação dos 400 pontos originais (cortesia do Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás - LAPIG) para 4.212 pontos; e Microsoft Office Excel 2007, para elaboração de gráficos;

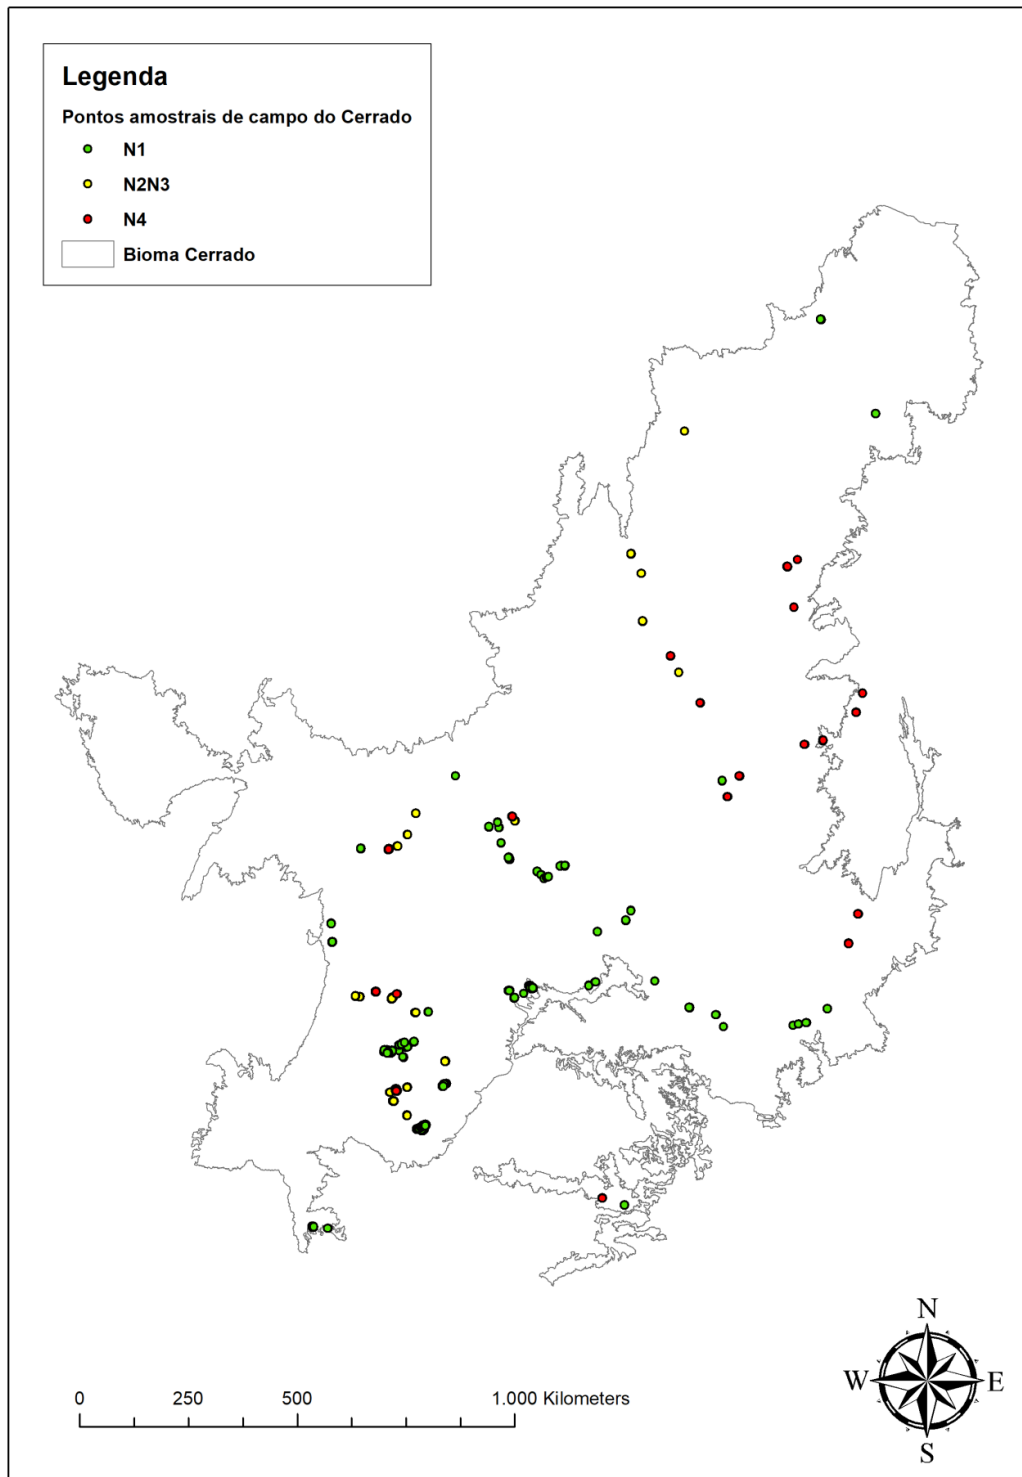
- Fotos *in situ* (cortesia do Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás - LAPIG);
- *Google Earth Engine*, para o acesso, processamento das imagens digitais e pontos georreferenciados com seus respectivos atributos. No *Google Earth Engine*, Nós também usámos: série temporal Sentinel-2 (6 meses), mapa de uso e cobertura da terra do Brasil do MapBiomas (versão 6) e imagens diárias de precipitação CHIRPS (6 meses e 2 anos).

Figura 25 – Mapa de localização da área de estudo.



Fonte: O autor.

Figura 26 – Distribuição espacial dos 4.212 pontos de pastagens usados no presente estudos com a identificação dos seus respectivos níveis de degradação.



Fonte: O autor.

3.2.3 Métodos

Na presente pesquisa realizou-se o processamento de uma série temporal de imagens Sentinel-2 (20m) entre os meses de março e agosto de 2019 de todo o bioma Cerrado. As bandas espectrais utilizadas foram: B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12. A seleção do período de obtenção das imagens é compatível com o período em que os dados de campo foram coletados no Cerrado, isto é, nos meses de março (época úmida/chuvosa), maio (período de transição) e agosto (época seca) de 2019. Inicialmente, foram coletados 400 pontos em campo (cortesia do Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás - LAPIG), e com o auxílio do *Google Earth*, Sistemas de Informação Geográfica e de técnicas de fointerpretação, estes pontos foram multiplicados para um total de 4.212.

O ciclo das chuvas no Cerrado é bastante similar tanto na parte norte, como na parte central, bem como na parte sul, conforme o gráfico da Figura 27 (a). A época úmida começa em finais de setembro ou início de outubro e termina em maio, já a época seca vai de maio a setembro, conforme a Figura 27 (b). Os dados das chuvas foram obtidos com base em imagens do satélite CHIRPS que fornece imagens globais diárias com dados de precipitação (mm/dia). A coleta dos 400 pontos foi realizada em época chuvosa/úmida (março), em período de transição (maio) e em época seca (agosto), deste modo, a seleção das imagens foi justamente de março a agosto de 2019.

O processamento da série temporal Sentinel-2 consistiu, primeiramente, na aplicação de um filtro espacial de remoção de nuvens, de modo a se obter uma série temporal de imagens Sentinel-2 livres de nuvens. Considerando que as imagens Sentinel-2 têm uma resolução temporal relativamente alta, isto é, de 5 em 5 dias, porém, estas mesmas imagens também são bastante afetadas por nuvens, e tendo em conta a grande extensão superficial do Cerrado, o que se traduz em volumosos conjuntos de dados para fins de processamento digital de imagens, o que se torna impraticável até mesmo com o uso do *Google Earth Engine*; deste modo, aplicou-se a mediana de 1 em 1 mês, isto é, mediana1 (março), mediana2 (abril), mediana3 (maio), mediana4 (junho), mediana5 (julho) e mediana6 (agosto). Assim, reduziu-se a dimensionalidade da série temporal de imagens Sentinel-2, conservou-se as características sazonais da mesma, e deste modo, tornou-se viável o processamento digital das imagens de todo o bioma Cerrado no *Google Earth Engine*. Posteriormente, com base na série temporal reduzida (10 bandas espectrais por mês), calculou-se os índices de vegetação

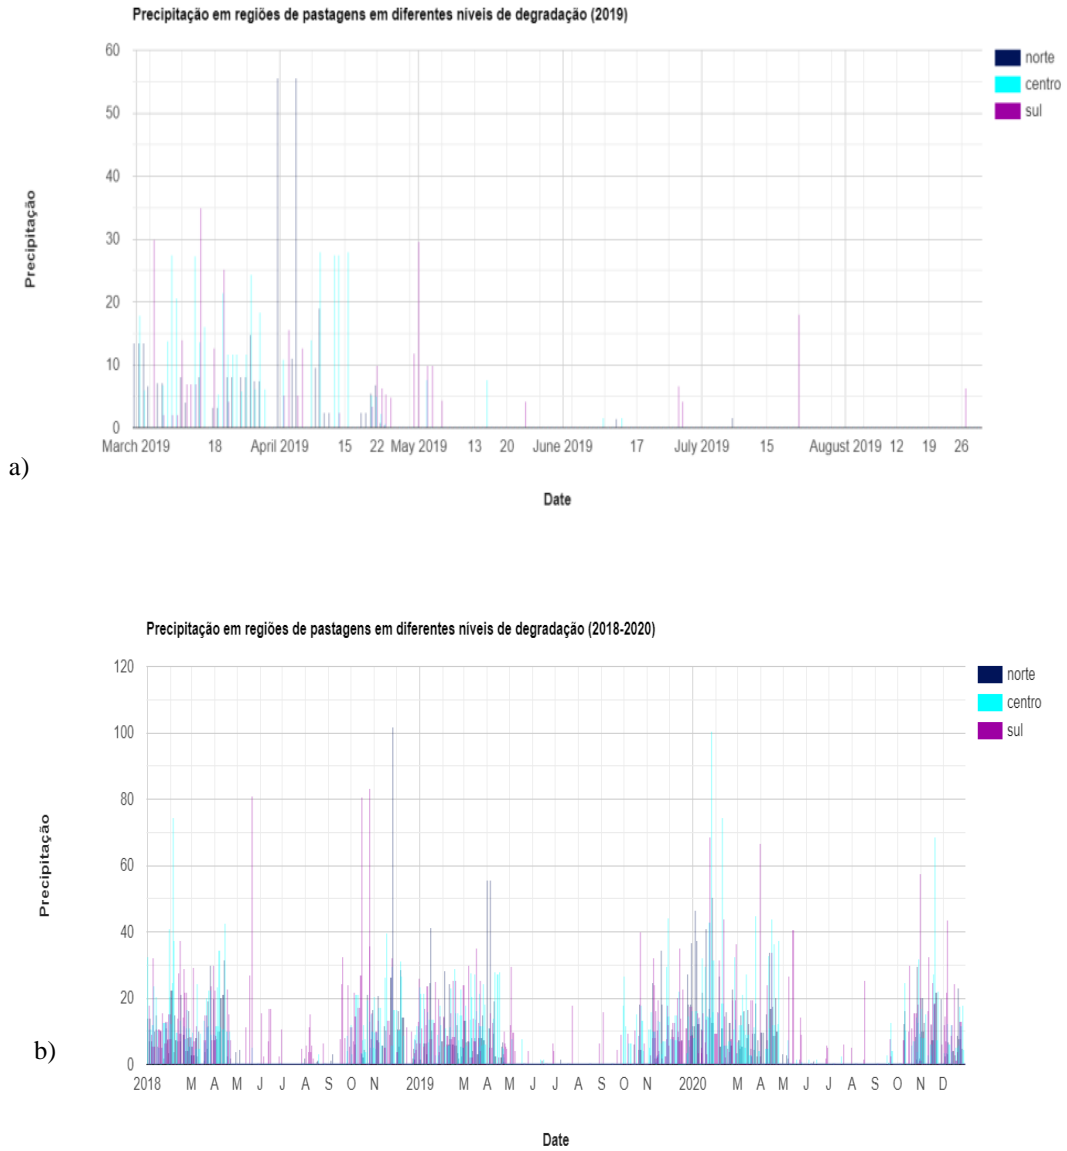
indicados na Tabela 11 (12 índices de vegetação por mês), isto é, 10 bandas espectrais por mês + 12 índices de vegetação por mês = 132 camadas de profundidade por mês do cubo de dados do Cerrado; além das grandes dimensões de extensão superficial do Cerrado, bem como a resolução espacial das imagens Sentinel-2 (20m), o que demonstra o grande poder de processamento do *Google Earth Engine*, considerando também a alta velocidade de processamento dos dados que é outra grande vantagem do *Google Earth Engine*.

Após o cálculo dos índices de vegetação, obtivemos um cubo de imagens de 132 camadas de profundidade por mês de todo o Cerrado (10 bandas espectrais por mês + 12 índices de vegetação por mês = 132 camadas por mês), ao qual aplicou-se a máscara da área de estudo obtida a partir de um arquivo vetorial e georreferenciado do Cerrado (IBGE, 2021b) e a máscara das áreas de pastagens – mapa de uso e cobertura da terra do MapBiomas versão 6, cujos pixels de pastagens correspondem ao valor 15 (MAPBIOMAS, 2021) –, obtendo-se assim um cubo de pixels contendo apenas as áreas de pastagens do bioma Cerrado.

Em seguida, com o cubo de pixels (pastagens) e os 70% das amostras de campo, efetuou-se o processo de classificação de imagens digitais com base no algoritmo de aprendizado de máquina *random forest*, empregando 500 árvores de decisão, o que resultou em uma imagem classificada nas 3 classes correspondentes aos níveis de degradação de pastagens: N1, N2N3 e N4.

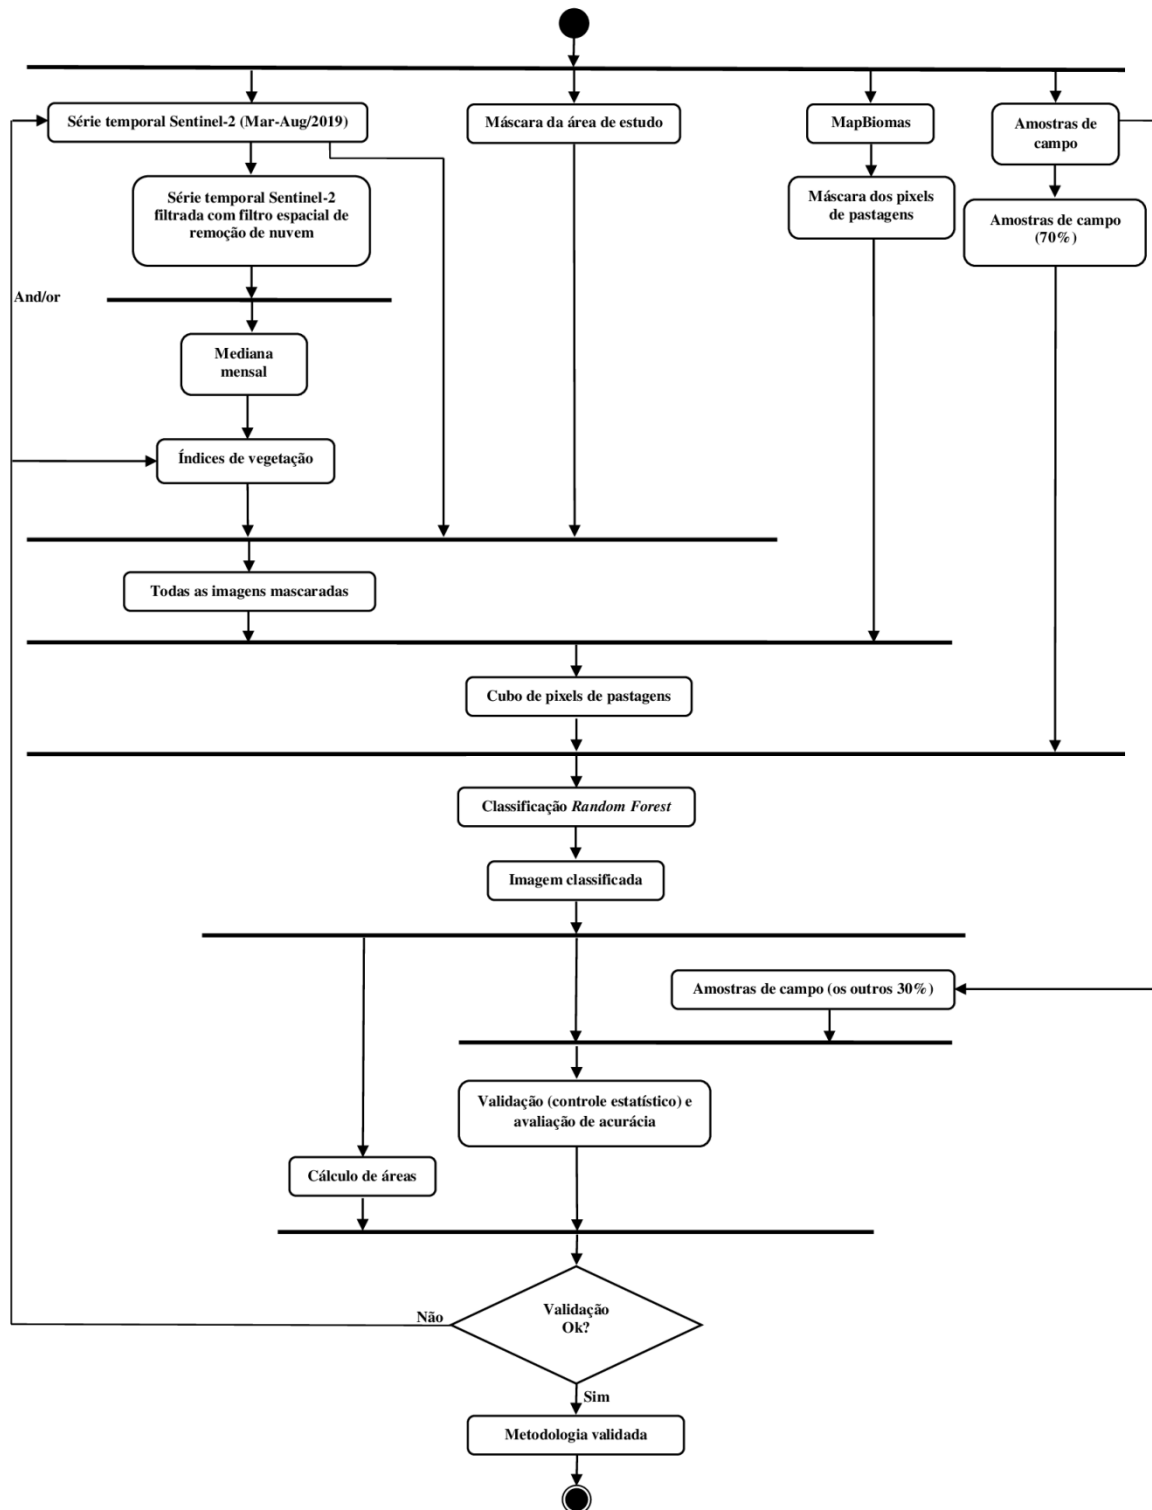
Uma vez obtida a imagem classificada, realizou-se a validação da mesma com base nos 30% restantes das amostras de campo. Durante a validação é realizado um controle estatístico e avaliação da acurácia da imagem classificada. Valores de Índice Kappa, Acurácia Global, Acurácia do Produtor, Acurácia do Usuário e *F-score* a partir de 0.7 correspondem a valores satisfatórios. Quando a validação é satisfatória, todos os resultados obtidos são definitivos. No caso de validação não satisfatória, é necessário redefinir os índices de vegetação (NCI, CRI2, STI, CAI, NDTI, NDVI, VIgreen, CRI1, RGR, NDI7, REP e TVI) e/ou redefinir as bandas espectrais puras (B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12) usados no presente estudo, conforme a Figura 28, de modo a se alcançar resultados satisfatórios (metodologia validada).

Figura 27 – Ciclo das chuvas do Cerrado: a) Período de março a agosto de 2019. b) Período de 2 anos (2018-2020).



Fonte: O autor.

Figura 28 – Fluxograma da metodologia proposta.



Fonte: O autor.

3.3 Resultados e discussões

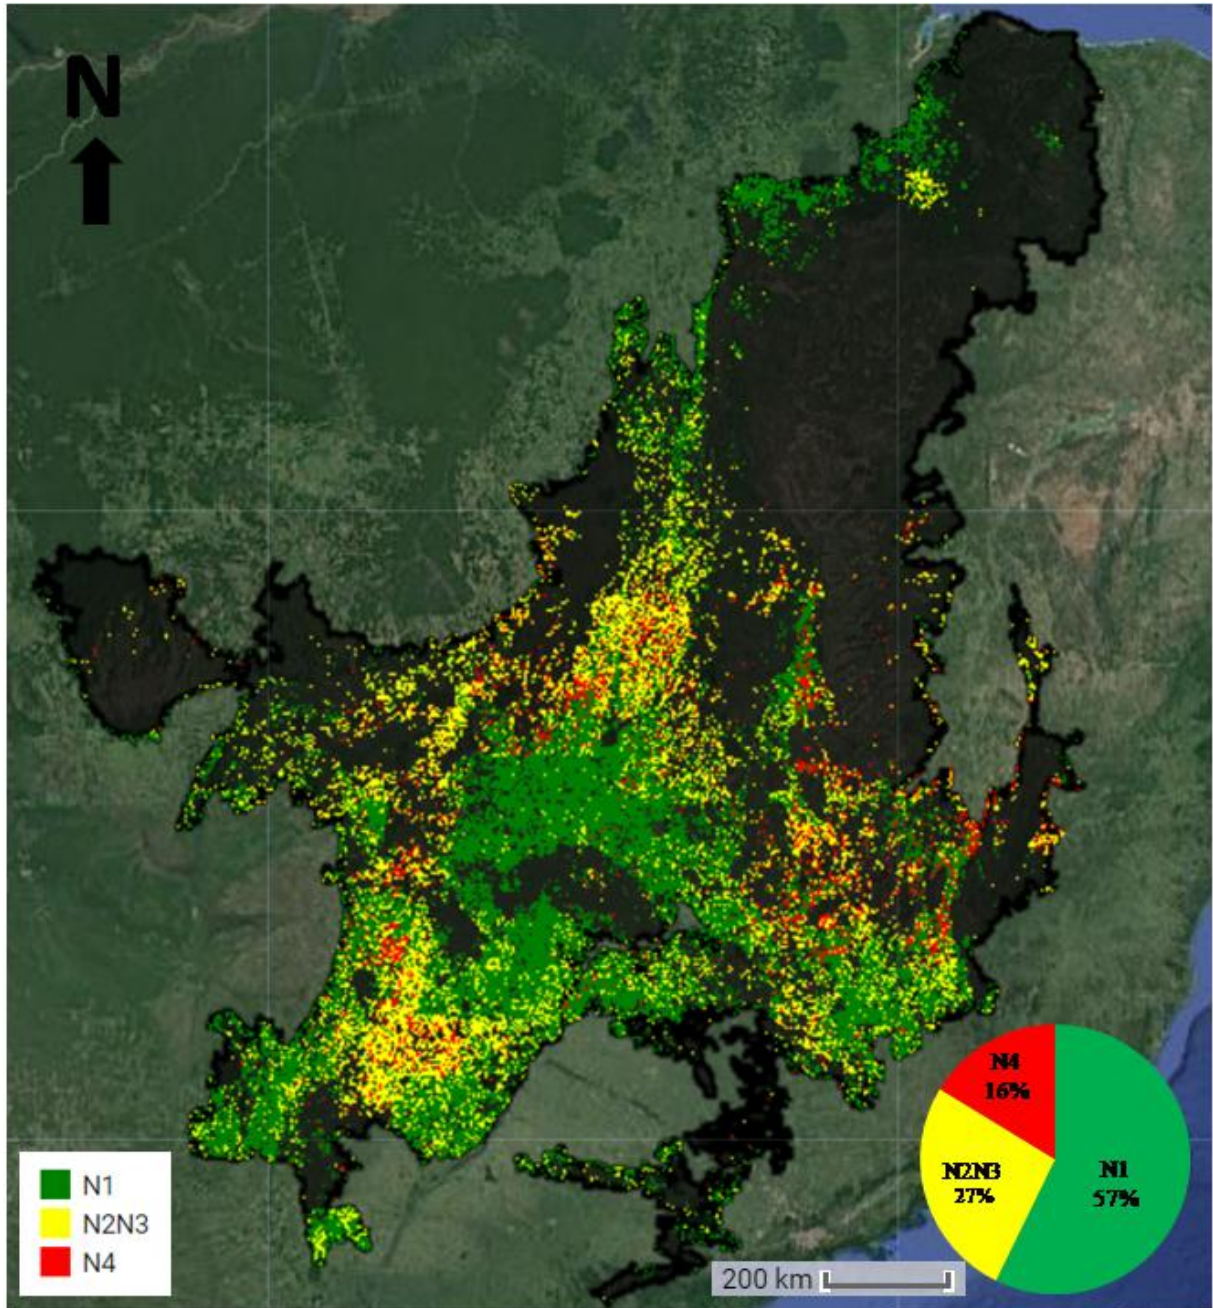
A aplicação da metodologia proposta no presente estudo proporcionou diversos resultados que serão apresentados e discutidos a seguir. A metodologia aplicada é um ajuste e simplificação da metodologia proposta no capítulo anterior (bioma Mata Atlântica), considerando as características edafoclimáticas e vegetacionais do Cerrado, bem como a grande extensão superficial do próprio Cerrado. A combinação dos índices de vegetação (NCI, CRI2, STI, CAI, NDTI, NDVI, VIgreen, CRI1, RGR, NDI7, REP e TVI) e das bandas espectrais puras (B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12), compatível com a resolução espacial de 20m do Sentinel-2, se mostrou eficiente para o monitoramento e mapeamento do processo de degradação de pastagens no Cerrado.

Com base no uso de uma série temporal de imagens Sentinel-2 de março a agosto de 2019, a remoção de pixels afetados por nuvens, aplicação de mediana mensal, cálculo dos índices de vegetação, a aplicação de máscaras das áreas de interesse e os 4.212 pontos de campo foi possível a obtenção de um cubo de pixels de pastagens, que posteriormente, foi classificado pelo método *random forest*, dando como resultado a imagem classificada das áreas de pastagens do bioma Cerrado, conforme a Figura 29.

A análise da acurácia, conforme a Tabela 12, apresenta os seguintes resultados: AG = 0.90, K = 0.84 e *F-score* (N1 = 0.90; N2N3 = 0.90; N4 = 0.90), os quais podem ser avaliados como bastante relevantes e significativos.

Na Tabela 12, com base nas bandas puras do Sentinel-2 (S2) e nos Índices de Vegetação (VI) temos as acurácias da classificação *random forest*, tais como, Acurácia Global, Kappa e F-score, para controlar a qualidade da separabilidade dos níveis de degradação de pastagens. Neste caso, a fórmula aplicada foi a seguinte: S2 + VI. Onde S2 = [B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12] e VI = [NCI, CRI2, STI, CAI, NDTI, NDVI, VIgreen, CRI1, RGR, NDI7, REP e TVI].

Figura 29 – Mapa dos níveis de degradação das pastagens do bioma Cerrado.



Fonte: O autor.

A obtenção destes resultados foi graças ao *Google Earth Engine* que é um ambiente computacional e poderosa ferramenta de processamento digital de imagens e sensoriamento remoto, sendo bastante robusto, alcançando alta velocidade de processamento, permitindo o processamento de grandes volumes de dados, realizando computação paralela e computação em nuvem, e dispondo de algoritmos de inteligência artificial e aprendizado de máquina, tal como o *random forest*, que se mostrou bastante eficaz e eficiente na classificação dos diferentes níveis de degradação de pastagens do Cerrado no presente estudo.

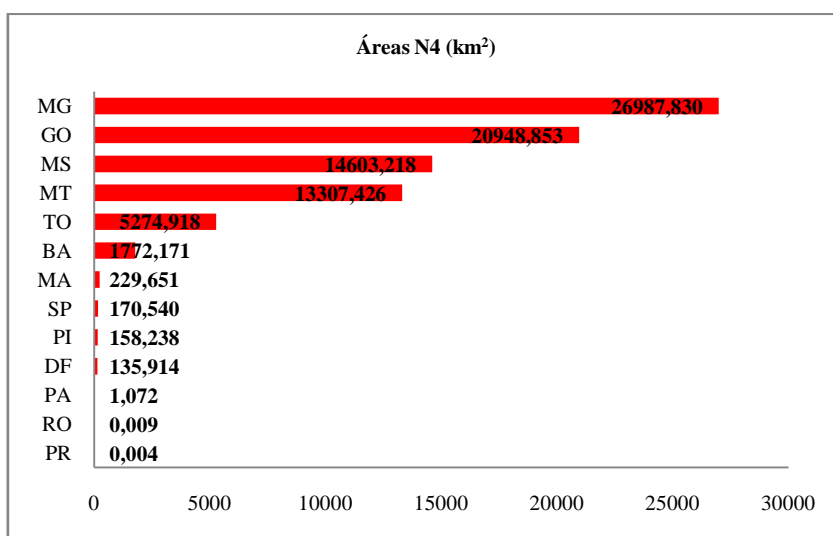
Tabela 12 – Controle da acurácia da classificação *random forest*.

Série temporal	Nível de Degradação	Acurácia do Produtor	Acurácia do Usuário	F-score	Acurácia Global	Kappa
6 meses (mar – ago)	N1	0.97	0.84	0.90		
	N2N3	0.92	0.88	0.90	0.90	0.84
	N4	0.85	0.95	0.90		

Fonte: O autor.

A partir da classificação dos diferentes níveis de degradação de pastagens do Cerrado foi possível extrair diversas estatísticas que dão uma melhor percepção do processo de degradação das pastagens a nível dos estados do Cerrado. Entre os principais estados com mais pastagens degradadas no nível N4, em ordem de importância, temos: MG, GO, MS e MT, com áreas de pastagens degradadas acima de 10.000 km², conforme Figura 30.

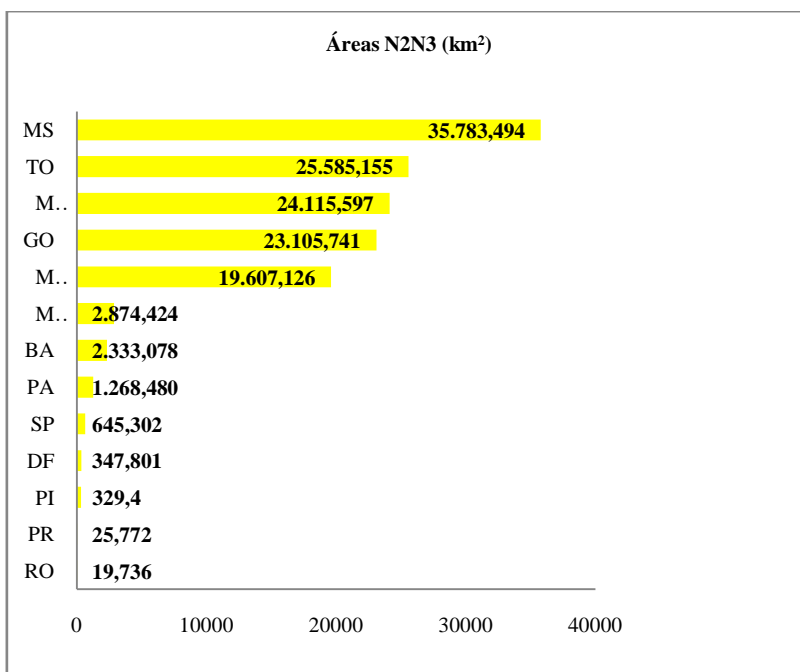
Figura 30 – Áreas de pastagens degradadas no nível N4 por estados do Cerrado.



Fonte: O autor.

Já os principais estados com pastagens degradadas no nível N2N3, em ordem de importância, são: MS, TO, MT, GO, MG, com quase cerca de 20.000 km² de pastagens degradadas, conforme a Figura 31.

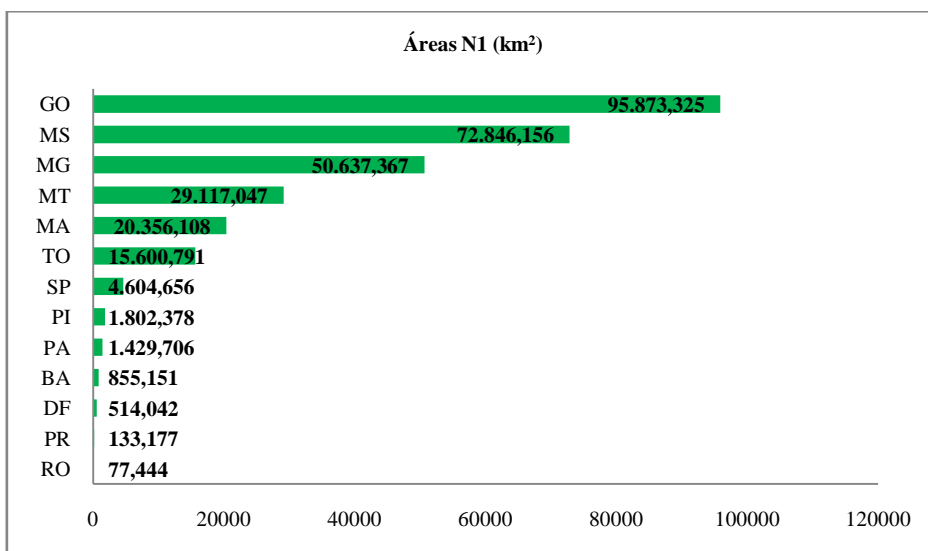
Figura 31 – Áreas de pastagens degradadas no nível N2N3 por estados do Cerrado.



Fonte: O autor.

Os principais estados que possuem as pastagens mais vigorosas e melhor conservadas no nível N1, em ordem de importância, são: GO, MS, MG, MT, MA, TO, com áreas de pastagens bem conservadas acima dos 15.000 km², conforme a Figura 32.

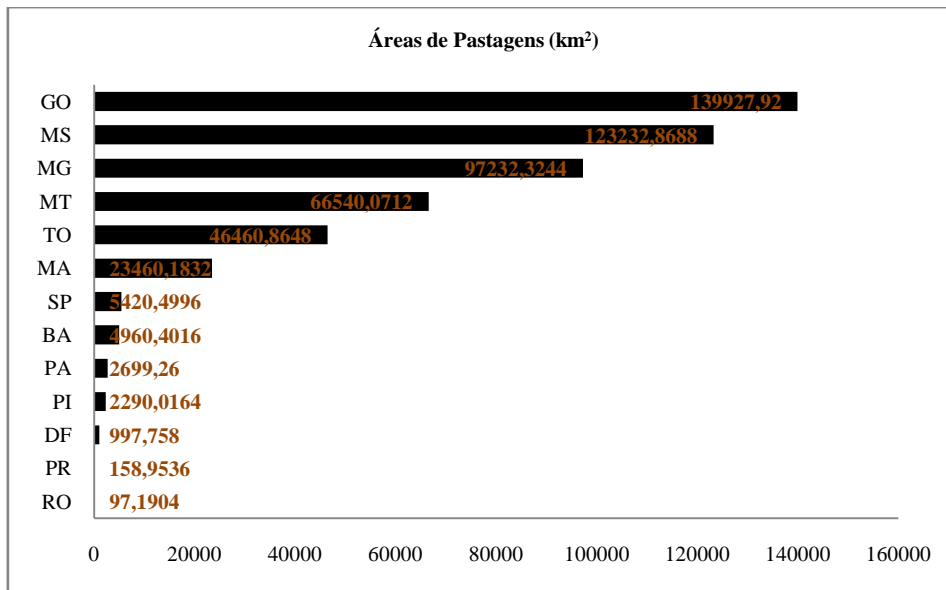
Figura 32 – Áreas de pastagens bem conservadas no nível N1 por estados do Cerrado.



Fonte: O autor.

De uma forma geral, os principais estados que mais possuem pastagens (N1+N2N3+N4), em ordem de importância, são: GO, MS, MG, MT, TO, MA, com áreas acima de 20.000 km² de pastagens. Uma análise completa das pastagens do Cerrado por estado é apresentada na Figura 33.

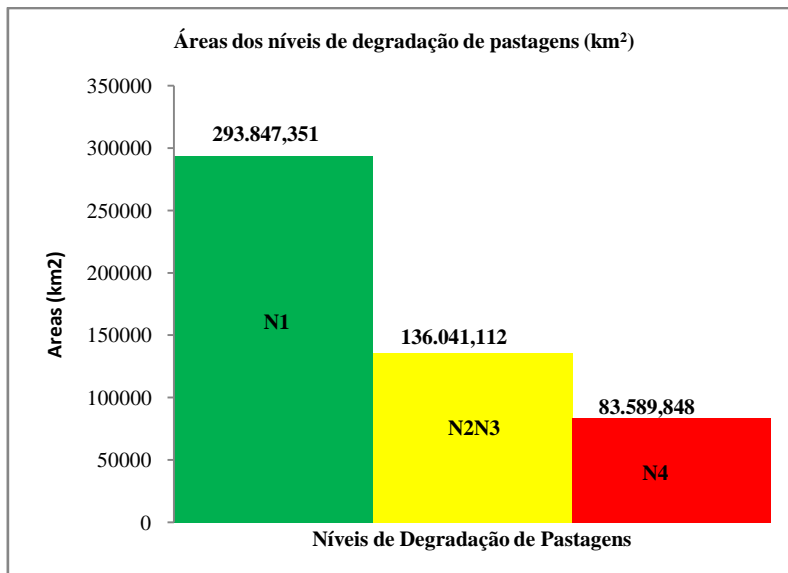
Figura 33 – Áreas totais de pastagens por estados do Cerrado.



Fonte: O autor.

O bioma Cerrado como um todo possui as seguintes estatísticas de áreas e percentagens de pastagens totais: N1 (293.847,351 km²; 57%), N2N3 (136.041,112 km²; 27%) e N4 (83.589,848 km²; 16%); totalizando cerca de 513.478,312 km², conforme Figura 34.

Figura 34 – Gráfico de áreas de pastagens totais do Cerrado.



Fonte: O autor.

Dada a importância do Cerrado para o setor agropecuário no Brasil (bioma com a maior produção agropecuária) os resultados são bastante preocupantes. Assim, é fundamental o incentivo, aplicação e fortalecimento de políticas públicas de recuperação de pastagens para

o Cerrado, tal como o Programa Agricultura de Baixo Carbono (ABC) e intensificação de sistemas de produção, tal como os sistemas de integração Lavoura-Pecuária-Floresta (iLPF), principalmente para os estados mais afetados com o processo de degradação de pastagens (MG, GO, MS, MT e TO), para o incentivo de ações regionais e locais. Os resultados obtidos nesta pesquisa científica apresentam consistências com os resultados nos estudos de Pereira et al. (2018).

A presente metodologia se mostrou eficaz, eficiente e robusta, permitindo alcançar com sucesso o objetivo proposto na presente pesquisa científica, isto é, identificar, monitorar e mapear a qualidade das pastagens/níveis de degradação das pastagens de todo o bioma Cerrado.

3.4 Conclusões

Para as condições estudadas relativamente aos níveis de degradação das pastagens chegou-se as seguintes conclusões:

- O objetivo da presente pesquisa científica foi alcançado, isto é, a metodologia proposta (S2 + VI) desempenhou com sucesso a função de identificar, monitorar e mapear os diferentes níveis de degradação das pastagens do Cerrado (N1, N2N3 e N4) com base em técnicas de Sensoriamento Remoto e Processamento Digital de Imagens, obtendo no processo de classificação *random forest* as acurácias $AG = 0.90$, $K = 0.84$ e $F\text{-score}$ ($N1 = 0.90$, $N2N3 = 0.90$, $N4 = 0.90$), alcançando resultados bastante relevantes e significativos.
- O *Google Earth Engine* foi fundamental no processamento digital de imagens e na classificação dos diferentes níveis de degradação das pastagens de todo o bioma Cerrado na presente pesquisa, devido a sua capacidade de processar volumosos conjuntos de dados, alta velocidade de processamento, processamento em nuvem, computação paralela, inteligência artificial e aprendizado de máquina, tal como o algoritmo *random forest*, se mostrando ser bastante robusto, eficiente e eficaz no presente estudo.
- Com base na classificação dos diferentes níveis de degradação de pastagens de todo o bioma Cerrado foi possível extrair informações úteis, tais

como os estados com as maiores taxas de pastagens degradadas do Cerrado, isto é, MG, GO, MS, MT e TO. Desse modo, é possível incentivar, aplicar e fortalecer políticas públicas de recuperação de pastagens degradadas do bioma Cerrado, como o Programa Agricultura de Baixo Carbono (ABC) e a intensificação de sistemas de produção como os sistemas de integração Lavoura-Pecuária-Floresta (iLPF), a níveis regional e local, entre outras medidas.

- Sendo o Cerrado o bioma com a maior produção agropecuária do Brasil, o cenário apresentado no presente estudo é bastante preocupante, sendo necessário a aplicação de medidas cabíveis de modo que se possa melhorar este quadro.

4 ANÁLISE DE MISTURA ESPECTRAL PARA A AVALIAÇÃO E MONITORAMENTO DOS NÍVEIS DE DEGRADAÇÃO DE PASTAGENS NO CERRADO, BRASIL. UMA ABORDAGEM DE SENSORIAMENTO REMOTO USANDO SENTINEL-2 E GOOGLE EARTH ENGINE

Resumo

Este estudo objetivou desenvolver uma metodologia baseada em Análise de Mistura Espectral (AME) com uso de imagens Sentinel-2 para o monitoramento e mapeamento dos níveis de degradação das pastagens de todo o bioma Cerrado. Assim, com base na literatura, os níveis de degradação das pastagens foram definidos como N1, N2N3 e N4, desde as pastagens mais vigorosas até as mais degradadas. O Cerrado é um dos 6 biomas do Brasil, correspondendo a 24% do território brasileiro e possuindo uma área superficial de 2.036.448 km². Os níveis de degradação de pastagens N1, N2N3 e N4 do bioma Cerrado foram identificados com base em 4.212 pontos georreferenciados coletados em campo. Usou-se imagens Sentinel-2; pontos de campo; criou-se uma máscara de ocorrência das pastagens a partir do mapa de Uso e Cobertura da Terra versão 6 do MapBiomas que é indicada pelo valor de pixel 15; realizou-se a Análise de Mistura Espectral (AME), tendo como componentes puros pixels de Vegetação Não-Fotossinteticamente Ativa (VNFA), Vegetação Fotossinteticamente Ativa (VFA), Solo Exposto (SE) e Sombra, gerando imagens-fração do mesmo nome e obtendo um Erro Médio Quadrático (EMQ) nas áreas de pastagens entre 0,001 e 0,03; e, finalmente, processou-se as imagens VNFA, VFA, SE e Sombra tanto da época úmida quanto da época seca no algoritmo de classificação *Random Forest*. O processamento das imagens digitais foi realizado no *Google Earth Engine*. A classificação *random forest* revelou que no bioma Cerrado tem-se N1 (46%), N2N3 (30%) e N4 (24%); e as precisões foram: Acurácia Global = 0,86; *Kappa* = 0,79; e *F-score* (N1 = 0,89, N2N3 = 0,86, N4 = 0,83). Com base no uso de imagens Sentinel-2 foi possível estimar as proporções VNFA+SE, VFA e Sombra para os diferentes níveis de degradação de pastagens, isto é, para N1 (VNFA+SE < 25%; VFA > 50%; Sombra < 25%), para N2N3 (VNFA+SE ≤ 25%; 40% < VFA < 60%; 30% < Sombra < 40%) e para N4 (VNFA+SE > 60%; VFA < 40%; Sombra ≤ 30%). Finalmente, sob as condições estudadas, a metodologia proposta provou ser robusta, eficiente e eficaz para o objetivo proposto da separabilidade dos níveis de degradação de

pastagens por meio de técnicas de Sensoriamento Remoto e Processamento Digital de Imagens de satélite Sentinel-2.

4.1 Introdução

O bioma Cerrado ocupa uma área superficial de 2.036.448 km², correspondendo a 24% do território brasileiro, sendo o segundo maior bioma do país (IBGE, 2022a, 2022b). O bioma Cerrado abrange os seguintes estados brasileiros: Bahia (BA; 27%), Distrito Federal (DF; 100%), Goiás (GO; 97%), Maranhão (MA; 65%), Mato Grosso (MT; 39%), Mato Grosso do Sul (MS; 61%), Minas Gerais (MG; 57%), Paraná (PR; 2%), Piauí (PI; 37%), Rondônia (RO; 1%), São Paulo (SP; 32%), Tocantins (TO; 91%), além de áreas disjuntas de Cerrado nos estados do Amapá (AP), Amazonas (AM), Pará (PA) e Roraima (RR); sendo que as percentagens correspondem às proporções do Cerrado nos respectivos estados (EMBRAPA, 2022; IBGE, 2022b). A área de pastagens do Cerrado é de cerca de 48.160.607 ha (MAPBIOMAS, 2021), considerando que a área total de pastagens do Brasil é de cerca de 150 milhões de hectares (MAPBIOMAS, 2021), o Cerrado possui cerca de 33% das pastagens de todo o Brasil. O Cerrado contribui com 55% da produção de carne do Brasil, sendo o bioma com a maior produção agropecuária do país (EMBRAPA, 2014a). Mais de metade das pastagens do Cerrado podem se encontrar em algum estágio de degradação, conseqüentemente, a recuperação destas pastagens poderia triplicar a produção de carne no Cerrado ou promover a expansão da agricultura, além de mitigar as emissões de gases de efeito estufa (EMBRAPA, 2014a). A principal característica da degradação das pastagens no Cerrado é a perda de produtividade devido a baixa oferta de água e de nutrientes (ARAGÃO et al., 2020). Sendo o Brasil um importante celeiro do mundo (GOMES et al., 2016) e um forte aliado às questões de segurança alimentar à nível global, ademais, considerando as projeções da ONU de rápido crescimento populacional global nos próximos anos, isto é, um crescimento populacional global de cerca de 8,5 bilhões de pessoas em 2030, 9,7 bilhões em 2050 e 10,9 bilhões em 2100 (ONU, 2019), e considerando as projeções da FAO de que a demanda mundial por alimentos de origem animal aumentará nos próximos anos, devido ao crescimento populacional e ao aumento do consumo per capita (FAO, 2021, 2009), o papel do Brasil na produção de alimentos torna-se cada vez mais indispensável para a segurança alimentar global. Estudos recentes indicam que, considerando as projeções de crescimento

populacional global, seria necessário duplicar a produção de alimentos para garantir a segurança alimentar global até o ano de 2050 (FOLEY et al., 2011; FORMAGGIO; SANCHES, 2017). Por estes e outros motivos a problemática da presente pesquisa científica é de suma importância do ponto de vista de segurança alimentar global, bem como do ponto de vista ambiental.

Do ponto de vista ambiental, a pecuária contribui nas emissões de gases de efeito estufa (GEE) como dióxido de carbono (CO₂), metano (CH₄) e óxido nitroso (N₂O) (FAO, 2009). Segundo o IPCC, as atividades humanas têm tido um impacto sem precedentes nas emissões de gases de efeito estufa na atmosfera, contribuindo para o aquecimento global, que hoje está em torno de 1,07°C acima dos níveis pré-industriais e existe a preocupação de conter o aquecimento global abaixo de 1,5°C (IPCC, 2021). O Brasil, em sua Contribuição Nacionalmente Determinada (NDC) do Acordo de Paris, com base no ano de 2005, se comprometeu a reduzir as emissões de gases de efeito estufa em até 37% e 43% em 2025 e 2030 respectivamente, além de alcançar a neutralidade climática (emissões líquidas zero) em 2060 (GOVERNMENT OF THE FEDERATIVE REPUBLIC OF BRAZIL, 2015, 2020).

A produção de alimentos e energia, bem como a exploração dos recursos naturais têm levado a biodiversidade global e suas funções ecológicas a um nível de pressão antrópica sem precedentes, ameaçando severamente a sua subsistência (PIRATELLI; FRANCISCO, 2013). As ações antrópicas têm causado a perda e fragmentação de habitats, a degradação ambiental, bem como a superexploração de recursos naturais ao redor do mundo (PIRATELLI; FRANCISCO, 2013). Considerando que a vegetação corresponde a uma das componentes mais importantes dos ecossistemas (JENSEN, 2011), a perda de habitat pode ser considerada a principal ameaça à biodiversidade em ambientes terrestres (PIRATELLI; FRANCISCO, 2013), ademais, a subsistência da biosfera deve-se às plantas que realizam a função ecológica de conversão da energia solar em alimento (CHRISTOPHERSON, 2012). O desflorestamento é considerado a principal alteração humana na Terra, provocado devido o desenvolvimento e a expansão das civilizações, que por sua vez, promovem o consumo das florestas e de outros recursos naturais (CHRISTOPHERSON, 2012). Estima-se que já se perdeu mais de metade das florestas tropicais e equatoriais primárias da Terra, para dar lugar a áreas de pastagens, cultivo agrícola, produção de madeira e combustível (CHRISTOPHERSON, 2012). Os serviços ecossistêmicos tais como produção de oxigênio, sequestro de carbono, produção de alimentos, formação de solos, produção primária de energia química por meio de energia solar, reciclagem de nutrientes, produção de madeira, controle do fluxo da água e transferência para a atmosfera, ou num sentido mais amplo, os sistemas físicos, químicos e

biológicos da Terra realizam um trabalho “natural” da ordem dos 35 trilhões de dólares anuais para a economia global (CHRISTOPHERSON, 2012; LONGLEY et al., 2013).

As pastagens degradadas são um empecilho ao aumento da produtividade de carne, bem como prejudiciais ao meio ambiente (ARAÚJO, 2011; DIAS-FILHO, 2013, 2015). Deste modo, a Recuperação de pastagens degradadas é uma estratégia de suma importância para a produção de alimentos (agropecuária), bem como na conservação e preservação do meio ambiente. Desse modo, o surgimento de programas e iniciativas nacionais e internacionais, que visam incentivar a recuperação de pastagens degradadas, bem como o uso de técnicas de agricultura de baixo carbono como a integração Lavoura-Pecuária-Floresta (iLPF), são cada vez mais importantes dado o papel do Brasil no cenário internacional relativamente a produção de alimentos. Entre estes programas se destacam o Plano ABC, Plano ABC+ e o Projeto Rural Sustentável.

Assim, o Projeto Rural Sustentável (Fase I) visa a qualificação e capacitação dos produtores rurais, a prestação de assistência técnica, bem como o apoio ao desenvolvimento de técnicas, metodologias e pesquisas científicas que promovam tecnologias de baixa emissão de carbono nos biomas Mata Atlântica e Amazônia (CNA, 2022b). Este projeto surgiu da parceria do Governo do Reino Unido (financiador) e do Ministério da Agricultura, Pecuária e Abastecimento (MAPA), sendo o Banco Interamericano de Desenvolvimento (BID) o responsável pela execução (CNA, 2022b). A Fase I do Projeto Rural Sustentável foi voltada apenas para os biomas Mata Atlântica e Amazônia (CNA, 2022b). Porém, a Fase II é voltada ao bioma Cerrado (RURAL SUSTENTÁVEL CERRADO, 2022). O Projeto Rural Sustentável – Cerrado tem como objetivo geral a mitigação das emissões de gases de efeito estufa, bem como incrementar a renda de pequenos e médios produtores rurais, favorecendo o uso de técnicas de baixa emissão de carbono (RURAL SUSTENTÁVEL CERRADO, 2022).

Os objetivos do Projeto Rural Sustentável – Cerrado serão alcançados por meio de implantação de sistemas de integração Lavoura-Pecuária-Floresta (iLPF) e de recuperação de pastagens degradadas (RURAL SUSTENTÁVEL CERRADO, 2022). O Projeto Rural Sustentável incentiva o desenvolvimento rural sustentável, a conservação da biodiversidade, bem como fortalece o alcance dos objetivos do Plano ABC (RURAL SUSTENTÁVEL, 2022).

Já o Plano ABC surgiu como demanda do compromisso assumido pelo Brasil na COP15, que teve lugar em Copenhague em 2009 (MAPA, 2012). O plano ABC surge devido a crescente preocupação mundial com as questões ambientais, especificamente, com o aquecimento global e com as mudanças climáticas nos anos vindouros (MAPA, 2012). O

Brasil tem desenvolvido um papel de liderança nessa temática (MAPA, 2012). Desse modo, o Brasil assumiu o compromisso de até 2020 reduzir as emissões de gases de efeito de estufa (GEE) em até 36,1 % e 38,9%, correspondendo à 1 bilhão de toneladas de CO₂ (MAPA, 2012; ZIMMER et al., 2012). O combate ao aquecimento global está de mãos dadas com o crescimento econômico sustentável e o combate a pobreza (MAPA, 2012). O plano ABC é uma política pública que apresenta detalhadamente os caminhos que o Brasil pretende seguir para alcançar com sucesso as metas afirmadas no seu compromisso de redução dos Gases de Efeito Estufa (MAPA, 2012). Os órgãos envolvidos são: A Casa Civil da Presidência da República, o Ministério da Agricultura, Pecuária e Abastecimento (MAPA), o Ministério do Desenvolvimento Agrário e a sociedade civil (MAPA, 2012).

A iLPF é uma estratégia agropecuária de produção que usa diferentes sistemas produtivos, agrícolas, pecuários e florestais numa mesma área, podendo ocorrer em consórcio, rotação ou sucessão, promovendo a interação dos componentes e gerando benefícios para todas as componentes do sistema (REDEILPF, 2021). A iLPF promove diversos benefícios ao meio ambiente, entre eles: redução das emissões de Gases de Efeito Estufa, conservação do solo, redução da abertura de novas áreas, melhora a ciclagem dos nutrientes, melhora o bem-estar animal, além de favorecer a manutenção da biodiversidade (REDEILPF, 2021). Em 2009, o Plano de Agricultura de Baixo Carbono (Plano ABC) consistiu em aumentar em 4 milhões de hectares a área de iLPF do país (REDEILPF, 2021). O incremento de 5,96 milhões de hectares, entre os anos de 2010 e 2015, permitiu o sequestro de 21,8 milhões de toneladas de CO₂ (REDEILPF, 2021). Em 2016, no Acordo de Paris sobre as Mudanças Climáticas, o Brasil assumiu o compromisso de aumentar mais 5 milhões de hectares de sistemas iLPF, visando alcançar em 2030 cerca de 9 milhões de hectares de iLPF (REDEILPF, 2021). A segunda fase do Plano ABC (ABC+) visa reduzir as emissões de Gases de Efeito Estufa até 2030, como estratégia de combate às mudanças climáticas (MAPA, 2021a). Lançado em abril de 2021, o ABC+ tem a finalidade de promover o desenvolvimento de soluções tecnológicas sustentáveis que impulsionem a produtividade no campo, bem como melhorar a renda dos produtores rurais (MAPA, 2021a). Atualmente, o Brasil possui uma área de cerca de 17,4 milhões de hectares de iLPF, tendo como meta até 2030 dobrar essa área para 35 milhões de hectares de iLPF (REDEILPF, 2021). A iLPF é uma das tecnologias mais importantes para que se possa alcançar as metas dos planos ABC e ABC+ (MAPA, 2021a; REDEILPF, 2021).

A produção agrícola global das maiores economias do mundo tem como objetivo alimentar bilhões de pessoas (JENSEN, 2016). Consequentemente, muito investimento tem sido realizado no desenvolvimento de sistemas de sensoriamento remoto e algoritmos

especializados em extrair informações úteis das imagens digitais de satélite relativamente às características biofísicas da vegetação (CRÓSTA, 1992; GONZALEZ; WOODS, 2010; JENSEN, 2016; MENESES; ALMEIDA, 2012). O sensoriamento remoto em consonância com outras ciências como a cartografia, sistemas de informação geográfica e o levantamento (JENSEN, 2011) são essenciais na gestão dos recursos naturais, além de desempenhar um papel fundamental no monitoramento ambiental global e local (LONGLEY et al., 2013). O sensoriamento remoto proporciona a grande vantagem de coletar dados de vastas áreas em pouco tempo, com grande repetitividade e baixo custo ao usuário (LORENZZETTI, 2015). O sensoriamento remoto e o SIG são tecnologias complementares, pois o sensoriamento remoto favorece a obtenção de dados de forma rápida e confiável, já o SIG torna possível a interação destes dados com outros tipos de produtos (GUERRA; JORGE, 2017). Diversas aplicações de sensoriamento remoto e sistemas de informação geográfica em estudos ambientais e no setor da agropecuária têm sido abordadas na literatura (BLASCHKE; KUX, 2007; COSME, 2012; FERREIRA, 2004; FITZ, 2008; FONSECA; FERNANDES, 2004; FORMAGGIO; SANCHES, 2017; GORGENS; SILVA; RODRIGUEZ, 2014; MATOS, 2008; MENEZES; FERNANDES, 2013; NOVO, 2010; PAESE et al., 2015; SAUSEN; LACRUZ, 2015; ZANOTTA; FERREIRA; ZORTEA, 2019).

O Sensoriamento Remoto e a análise de mistura espectral têm sido aplicados com sucesso em estudos de estimativas quantitativas da cobertura das proporções de biomassa vegetal, isto é, vegetação não-fotossinteticamente ativa, vegetação fotossinteticamente ativa, solo exposto e sombra (ASNER et al., 2005; ASNER; BORGHI; OJEDA, 2003; ASNER; LOBELL, 2000; DAVIDSON et al., 2009; GUERSCHMAN et al., 2009; LI et al., 2016; LI; GUO, 2016; MAYES et al., 2017; MAYES; MUSTARD; MELILLO, 2015; MEYER; OKIN, 2015; NUMATA et al., 2007, 2008; OKIN et al., 2001; ROBERTS; SMITH; ADAMS, 1993), porém existe a preocupação de obtenção de metodologias mais robustas, exatas e precisas que possibilitem a obtenção de resultados cada vez mais confiáveis que expressem com maior exatidão a realidade de campo. Neste estudo, a metodologia proposta é baseada em análise de mistura espectral (imagens-fração), classificação *random forest* e validação com amostras de campo. Este estudo tem como objetivo propor uma metodologia de monitoramento e avaliação dos níveis de degradação das pastagens por meio de análise de mistura espectral e técnicas de Sensoriamento Remoto e Processamento Digital de Imagens.

4.2 Revisão bibliográfica

4.2.1 Trabalhos relacionados

Nessa seção realizou-se uma pesquisa bibliográfica dos estudos científicos mais relevantes relativamente ao tema de degradação de pastagens na ótica do Sensoriamento Remoto.

Numata et al. (2007) estudaram a degradação de pastagens no bioma da Amazônia Brasileira, no Estado de Rondônia, na estação seca. Para tal, utilizaram imagens Landsat-TM às quais aplicaram a Análise de Mistura Espectral (AME) derivando desta as frações Vegetação Não Fotossinteticamente Ativa (VNFA), Vegetação Fotossinteticamente Ativa (VFA), Solo Exposto (SE) e VNFA+SE. Ademais, Numata et al. (2007) utilizaram o Erro Médio Quadrático (EMQ) da seleção das amostras de entrada (pixels puros) como forma de controle da qualidade da AME. Além disso, Numata et al. (2007) também utilizaram quatro índices de vegetação NDII5, NDII7, NDVI e SAVI. Os autores correlacionaram cada um desses índices com as medidas biofísicas de campo (NUMATA et al., 2007). A VNFA apresentou maior correlação com as medidas biofísicas do que os demais parâmetros, sendo indicada como um bom indicador das características da pastagem. A VNFA é um bom indicador da degradação de pastagens (NUMATA et al., 2007).

Um outro estudo bastante interessante é o de Guerschman et al. (2009). Este estudo se baseia na Análise de Mistura Espectral para a estimativa das proporções de VNFA, VFA e solo exposto (SE) (GUERSCHMAN et al., 2009). Além disso, com base nas imagens dos sensores EO-1 Hyperion e MODIS, os autores geraram os índices CAI (Índice de Absorção da Celulose, com base nas bandas espectrais do sensor EO-1 Hyperion) e NDVI (produto do MODIS) (GUERSCHMAN et al., 2009). Com os índices CAI e o NDVI foi possível construir um espaço de atributos 2D, onde todos os pixels são plotados (GUERSCHMAN et al., 2009). Esse espaço de atributos 2D deu origem a um triângulo chamada triângulo CAI-NDVI que representa a relação de VNFA, VFA e SE, sendo que esses elementos considerados puros estavam localizados no vértice do triângulo, e os demais elementos considerados pixels misturados estavam localizados no interior do triângulo (GUERSCHMAN et al., 2009). Assim, os pixels que possuem um baixo NDVI e um baixo CAI possuem maiores proporções de solo exposto, ou podem ser pixels puros de SE (GUERSCHMAN et al., 2009). Já os pixels

que possuem um alto NDVI e um baixo CAI possuem maiores proporções de VFA, ou podem ser pixels puros de VFA (GUERSCHMAN et al., 2009). E pixels que possuem tanto NDVI alto e CAI alto, possuem maiores proporções de VNFA, ou podem ser pixels puros de VNFA (GUERSCHMAN et al., 2009).

Um outro estudo bastante interessante, é o trabalho de Li and Guo (2016), que também menciona os dois trabalhos anteriores. Os autores mencionam a Análise de Mistura Espectral (AME) para a estimativa das proporções de VNFA, VFA e SE, além dos índices CAI e NDVI derivados das imagens EO-1 Hyperion e MODIS, respectivamente Li and Guo (2016), em citação dos estudos de Guerschman et al. (2009). Li and Guo (2016) apresentam características muito interessantes do comportamento espectral da VNFA, VFA e SE. Algumas delas são apresentadas a seguir:

Na faixa do visível (400 a 700 nm) o sinal da VNFA é maior do que a VFA devido a ausência de absorção da luz pelos pigmentos fotossintetizantes (clorofilas a e b); Na faixa do infravermelho-próximo o VNFA é menor do que o VFA devido a mudança da estrutura das folhas. No infravermelho-médio (1100 – 2500 nm) o conteúdo de água regula as respostas da celulose e da lignina no sinal da VFA; Na faixa 2100-2300 nm o sinal do VNFA é muito forte devido a presença de celulose e lignina, havendo uma boa distinção com o sinal do VFA (LI; GUO, 2016). Sendo as curvas espectrais da VNFA e do SE bastante similares no visível e no infravermelho-próximo, a sua separação torna-se difícil (LI; GUO, 2016). Desse modo, a VNFA pode ser distinguida do SE no infravermelho-médio devido à característica única de absorção da celulose e da lignina entre 2090-2300 nm ; Assim, o CAI (Índice de Absorção da Celulose) é usado para distinguir a VNFA do solo exposto (LI; GUO, 2016). Na transição do visível e infravermelho-próximo encontra-se a posição red-edge (680 a 780nm) que é sensível para o conteúdo de clorofila; Red-edge Chlorophyll Index tem uma melhor performance do que os Índices de vegetação como o NDVI, usado para diferenciar VFA do VNFA; Red-edge slope: VNFA é normalmente maior do que o solo exposto; A faixa de 400 a 2500 nm tem a possibilidade para separar VNFA, VFA e SE (LI; GUO, 2016).

Um outro estudo na mesma perspectiva é de Roberts et al. (1993), segundo o qual, com base no sensor hiperespectral AVIRIS que possui 224 bandas, realizaram a separação da VNFA e do SE por meio da resposta da lignina no infravermelho-próximo. Também utilizaram a Análise de Mistura Espectral (AME) para separar a VNFA, a VFA e o SE (ROBERTS; SMITH; ADAMS, 1993).

Outro estudo pertinente é o de Delegido et al. (2013). Nesse estudo utilizaram-se imagens hiperespectrais CHRIS/PROBA, e fez-se algumas suposições com imagens Sentinel-

2 (antes do lançamento), para realizar o monitoramento do crescimento da lavoura (DELEGIDO et al., 2013). Os autores trabalharam com o parâmetro biofísico índice de Área Foliar (IAF), e um índice *red-edge* NDI (Índice de Diferença Normalizada) que apresentou uma correlação muito alta com o IAF, comparativamente ao índice tradicional NDVI (DELEGIDO et al., 2013). A pesquisa concluiu que esse índice espectral *red-edge* NDI é uma forte alternativa para a estimativa do IAF (DELEGIDO et al., 2013).

Um outro estudo na mesma vertente das pastagens degradadas é o de Wang and Qu (2007). Esse estudo utiliza dados MODIS para calcular o índice NDMI que é um índice proposto para o monitoramento da umidade do solo e da vegetação (WANG; QU, 2007). É um índice adequado para a estimativa da umidade da vegetação e do solo Wang and Qu (2007). A sua aplicação em regiões com cobertura vegetal moderada ainda precisa de mais investigação (WANG; QU, 2007).

Estudos de Daughtry et al. (2004) também utilizaram a Análise de Mistura Espectral (AME) para separar VFA, VNFA e SE com o auxílio do CAI, a Vegetação Não Fotossinteticamente Ativa (VNFA) apresentou uma correlação de 0,89 com o CAI, já o VFA apresentou uma correlação de 0,93 com o NDVI (DAUGHTRY; HUNT; MCMURTREY, 2004).

Num outro estudo de Daughtry et al. (2006), os índices vegetação calculados a partir de imagens Landsat como o NDTI, NDI5, NDI7 e NDSVI apresentaram correlação fraca com a Vegetação Não Fotossinteticamente Ativa (VNFA), já o CAI derivado do EO-1 Hyperion apresentou correlação alta de 0,85 em maio e de 0,77 em junho (DAUGHTRY et al., 2006).

Um estudo muito interessante e pertinente à presente pesquisa foi o de Asner and Heidebrecht (2002). Esse estudo usa Análise de Mistura Espectral (AME) gerando as proporções de VNFA, VFA e SE, fazendo uma comparação entre produtos advindos de sensores multiespectrais com produtos advindos de sensores hiperspectrais (ASNER; HEIDEBRECHT, 2002). Esse estudo concluiu que existem limitações claras em todo o intervalo ótico (0,4 – 2,5 μm) ou no visível - infravermelho próximo (0,4 – 1,3 μm) para decompor os pixels das imagens em VNFA, VFA e SE (ASNER; HEIDEBRECHT, 2002). Os autores acreditam que a melhor faixa do espectro para separar VNFA, VFA e SE seja o infravermelho médio 2 (ASNER; HEIDEBRECHT, 2002).

Estudos de Numata et al. (2008) utilizaram dois índices de vegetação (NDVI e NDWI), quatro frações derivadas da AME (VNFA, VFA, SE e CCD; onde o CCD é medido em campo e igual à VFA, Sombra e VNFA+SE) e quatro características de absorção espectral (NUMATA et al., 2008). Essas medições foram comparadas com biomassa aérea (viva e

senescente), e conteúdo de água da pastagem (NUMATA et al., 2008). As medidas de absorção de água entre 1100 e 1250 nm tiveram a maior correlação com a biomassa aérea (biomassa viva) e conteúdo de água no dossel (NUMATA et al., 2008). Já as medidas de absorção de ligno-celulose, entre 2045 e 2218 nm, tiveram a maior correlação com a biomassa senescente (NUMATA et al., 2008). Esses resultados vêm incentivar e reforçar o uso de dados hiperespectrais em estudos relacionados (NUMATA et al., 2008).

Os estudos de Aguiar et al. (2017) utilizaram uma série temporal de imagens EVI2/MODIS de 2000 à 2012 com a finalidade de estudar a degradação das pastagens nos estados do Acre, Pará e Mato Grosso do Sul. Os dados de campo foram obtidos na ocasião do Projeto Geodegrade (AGUIAR et al., 2017; EMBRAPA, 2012a, 2012b, 2013, 2014b). Nesse trabalho das 782 pastagens amostradas, 30,3 % estavam em processo de degradação biológica (AGUIAR et al., 2017). O estudo apontou que a fração não pastagem, extraída de fotografias verticais é um bom indicador de degradação de pastagens (AGUIAR et al., 2017). As frações utilizadas foram: a fração não pastagem (serrapilheira + solo + outros + invasoras) e a fração pastagem (verde + seca) (AGUIAR et al., 2017). Segundo o autor, as séries MODIS são potenciais indicadores de pastagens em processo de redução, reforma, recuperação ou renovação (AGUIAR et al., 2017).

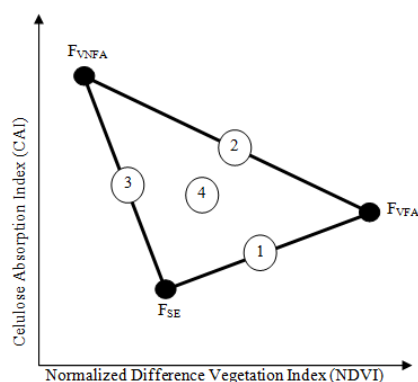
Outro estudo bastante interessante é o de (HILL, 2013), realizado em regiões de pastagem e savanas nos Estados Unidos da América, com base em imagens Sentinel-2 (simulações antes do lançamento), Landsat-8, MODIS, VIIRS (*Visible Infrared Imaging Radiometer Suite*) e EO-1 Hyperion a partir dos quais calculou-se diversos índices de vegetação tais como, NDVI, *Carotenoid Reflectance Index*, *Anthoyanian Reflectance Index* e o *Red-Green Ratio*; índices de conteúdo de água da paisagem e na vegetação, tais como, o *Normalized Difference Infrared Index*; além dos índices de vegetação senescente e de solo (*Short Wave Infrared Ratio*, *Plant Senescent Reflectance Index*); e o índice de biomassa herbácea (*Soil Adjusted Total Vegetation Index*) (HILL, 2013). O estudo concluiu que os tipos de uso da terra podem ser caracterizados com base nos histogramas de distribuição dos valores dos pixels e nas métricas estatísticas, podendo ser usadas como indicadores de estado e de mudança do uso da terra (HILL, 2013).

Para a detecção de pastagens degradadas por sensoriamento remoto é necessário dispor de determinados indicadores biofísicos que indiquem a existência ou não de degradação, sendo que a seleção desses indicadores não é uma tarefa trivial. Assim, elaborou-se uma metodologia que tem como base determinadas características que as pastagens degradadas apresentam relativamente aos seus parâmetros biofísicos. Assim, segundo a

revisão bibliográfica realizada observou-se que a VNFA (Vegetação Não Fotossinteticamente Ativa) seria um bom indicador de pastagens degradadas (ASNER; HEIDEBRECHT, 2002; GUERSCHMAN et al., 2009; NUMATA et al., 2008; REN et al., 2012; ROBERTS et al., 2003; ROBERTS; SMITH; ADAMS, 1993; YUE et al., 2010). A VNFA corresponde à vegetação que não realiza a função fotossintética, considerando-se principalmente, a biomassa seca no dossel ou palhada na superfície (LI; GUO, 2016). Os outros dois indicadores úteis nessa metodologia são a VFA (Vegetação Fotossinteticamente Ativa) que corresponde à vegetação verde fotossinteticamente ativa, e o SE (Solo Exposto). Em sensoriamento remoto, a VNFA e a VFA se distinguem bem no visível (400-700 nm) e no infravermelho-próximo (700-1200 nm), sendo o sinal da VNFA no visível normalmente maior que o da VFA devido à falta de absorção dos pigmentos (principalmente das clorofilas a e b (ASNER, 1998; CAO et al., 2010; LI; GUO, 2016), e menor que o sinal da VFA no infravermelho-próximo devido a mudança da estrutura das folhas (LI; GUO, 2016). No infravermelho médio (1100-2500nm) o conteúdo de água das folhas regula a resposta da celulose e da lignina no sinal da VFA (CAO et al., 2010). Por isso, existe uma boa distinção entre as reflectâncias da VNFA e da VFA entre 2100 e 2300 nm, devido ao forte sinal da reflectância da VNFA por causa da presença de celulose e de lignina na sua composição, o que não ocorre com o VFA (DAUGHTRY et al., 2005). Considerando que as curvas espectrais da VNFA e do SE são bastante similares no visível e no infravermelho-próximo, a sua separação torna-se difícil (AASE; TANAKA, 1991; DAUGHTRY et al., 1996; LI; GUO, 2016; NAGLER; DAUGHTRY; GOWARD, 2000). Desse modo, a VNFA pode ser distinguida do SE no infravermelho médio devido à característica única de absorção da celulose e da lignina entre 2090-2300 nm (ASNER, 1998; ELVIDGE, 1990; NAGLER; DAUGHTRY; GOWARD, 2000; STONER; BAUMGARDNER, 1981). As características únicas de absorção da lignina e da celulose têm sido usadas para desenvolver índices espectrais, tais como o índice de absorção de celulose (CAI) (DAUGHTRY et al., 1996; NAGLER; DAUGHTRY; GOWARD, 2000), que é um índice obtido a partir do sensor hiperespectral EO-1 Hyperion para discriminar a VNFA do SE. Assim, considerando essa semelhança nas respostas espectrais da VNFA e do SE, torna-se difícil separar espectralmente esses dois elementos só com base no espectro eletromagnético dos sensores orbitais. Assim, recorre-se a outras técnicas que favoreçam uma melhor distinção entre os elementos VNFA, VFA e SE. Uma dessas técnicas é a Análise de Mistura Espectral (AME), que permite fazer a separação dos pixels puros presentes na imagem. A AME é um método bastante usual na estimativa da cobertura da VNFA, quando o uso e a cobertura da Terra é uma combinação de VFA, VNFA e SE (LI; GUO, 2016). Vários

estudos têm sido realizados para a estimativa da VNFA desde os anos 1990. Entre esses estudos, alguns têm dedicado esforços para quantificar a cobertura da VNFA da mistura com a VFA, a VNFA e o SE em pastagens, savanas, e ecossistemas florestais (ASNER; HEIDEBRECHT, 2002; CAO et al., 2010; GUERSCHMAN et al., 2009; ROBERTS; SMITH; ADAMS, 1993; YUE et al., 2010). Esses estudos têm demonstrado o grande potencial do sensoriamento remoto passivo na estimativa da cobertura da VNFA. Porém, como as respostas espectrais dos pixels de VNFA e SE são bastante semelhantes, a seleção dos pixels puros diretamente em tela do computador torna-se inviável, sendo necessário a realização de um processamento auxiliar. Guerschman et al. (2009) propõem o cálculo dos índices CAI (por meio de dados hiperespectrais do sensor EO-1 Hyperion) e NDVI, que sendo plotados num espaço de atributos 2D, obtém-se uma separação satisfatória dos pixels de VNFA, VFA e SE. Estudos de Numata et al. (2008) realizados na Amazônia Brasileira para a estimativa da VNFA em pastagens sob pastejo com o uso de dados hiperespectrais demonstraram que esses dados têm um grande potencial na estimativa da VNFA (LI; GUO, 2016). O triângulo CAI-NDVI representa a relação entre a vegetação seca (VNFA), a vegetação verde (VFA) e o solo exposto (SE), sendo que esses elementos considerados puros estarão localizados nos vértices do triângulo, e os demais elementos considerados misturados estarão localizados no interior do triângulo (GUERSCHMAN et al., 2009), conforme a Figura 35.

Figura 35 – Relação do triângulo CAI-NDVI com os componentes puros (VNFA, VFA e SE) e misturados da imagem orbital.



Fonte: Adaptado de GUERSCHMAN et al., 2009.

Considerando que o programa EO-1 Hyperion encerrou em 2017 (USGS, 2017), achou-se conveniente não incluí-lo na presente metodologia de modo a não comprometer a sua continuidade. No entanto, o Sentinel-2 vem sendo um sensor bastante promissor devido às características espectrais das suas bandas que capturam faixas bastante detalhadas do espectro eletromagnético, tais como as faixas do azul, verde, vermelho, infravermelho-próximo e as

faixas do infravermelho médio (SWIR 1 e SWIR 2). Segundo Li and Guo (2016), alguns satélites como o Sentinel-2 fornecerão novas oportunidades para a estimativa da VNFA. Assim, de acordo com a revisão bibliográfica observou-se que as bandas espectrais do Sentinel-2 apresentam características espectrais que podem favorecer resultados promissores no estudo de degradação de pastagens. Na Tabela 2 apresentam-se as características das bandas espectrais do Sentinel-2. A posição red-edge (680-780 nm) é a transição do visível para o infravermelho-próximo, esta região é sensível à variação do conteúdo da clorofila (LI; GUO, 2016). O índice de clorofila red-edge tem demonstrado melhor desempenho do que os índices de vegetação verde, tais como o NDVI, na estimativa do conteúdo de clorofila em regiões de semiárido misto com pastagens (WONG; HE, 2013), cobertura do dossel verde no deserto hiper-árido do Atacama (CHÁVEZ et al., 2013), e o IAF verde em áreas de cultivo (VIÑA et al., 2011). Esses estudos têm demonstrado o potencial da posição red-edge para a diferenciação da VFA em relação à VNFA, considerando as suas diferenças na clorofila e na estrutura. Ao mesmo tempo, na posição red-edge o declive espectral da reflectância da VNFA é normalmente maior do que o do SE. No entanto, o declive da posição red-edge é influenciado pelas condições de umidade e da idade da VNFA (DAUGHTRY et al., 1996; GOWARD; HUENNERICH; WARING, 1994; NAGLER; DAUGHTRY; GOWARD, 2000), o uso da posição red-edge para a estimativa da VNFA indica que seria interessante um estudo mais profundo (LI; GUO, 2016). Assim, as regiões de 400-2500 nm do espectro contêm informações suficientes para separar a VNFA, a VFA e o SE (LI; GUO, 2016).

4.3 Análise de Mistura Espectral (AME)

Num determinado espaço geográfico, os alvos no terreno tendem a ser mais heterogêneos do que homogêneos, desse modo, na passagem do satélite por esse espaço, dentro do seu campo de visada instantâneo (IFOV), os detectores registram a radiação eletromagnética refletida pelos diferentes alvos no terreno que compõe a cena, sendo que a resposta espectral registrada em cada detector do satélite é uma média das respostas espectrais dos alvos correspondentes no terreno (CAMARA; VALERIANO; VIANEI, 2013; JENSEN, 2016; LILLESAND; KIEFER; CHIPMAN, 2015; MATHER; KOCH, 2011; PONZONI; SHIMABUKURO; KUPLICH, 2012; SHIMABUKURO; PONZONI, 2017; ZANOTTA; FERREIRA; ZORTEA, 2019). Consequentemente, os pixels de uma imagem também acabam

por ser afetados, recebendo o nome de "pixels misturados" (CAMARA; VALERIANO; VIANEI, 2013; LILLESAND; KIEFER; CHIPMAN, 2015; PONZONI; SHIMABUKURO; KUPLICH, 2012).

Dependendo das características dos alvos no terreno, a mistura espectral pode ser linear ou não-linear, porém o modelo linear é amplamente utilizado por pesquisadores e apresenta resultados consistentes (PONZONI; SHIMABUKURO; KUPLICH, 2012). Análise de Mistura Espectral (AME) tem a finalidade de estimar a proporção dos componentes (pixels puros) da mistura espectral, para cada pixel das bandas selecionadas do sensor em questão, resultando assim, nas imagens-fração com o mesmo nome dos pixels puros.

A AME requer a satisfação de duas condições básicas para cada pixel em uma imagem. Na primeira condição, a soma das proporções de todos os componentes puros incluídos em um pixel deve ser igual a 1. A Expressão matemática é a seguinte:

$$\sum_{i=1}^N F_i = F_1 + F_2 + \dots + F_N = 1 \quad (1)$$

onde F_1, F_2, \dots, F_N representam as proporções dos N possíveis componentes puros contidos em um pixel (LILLESAND; KIEFER; CHIPMAN, 2015).

Na segunda condição, para uma dada banda espectral λ , o número digital observado DN_λ para cada pixel é considerado como uma combinação linear de cada componente puro dentro do pixel, mais um erro desconhecido (LILLESAND; KIEFER; CHIPMAN, 2015). Esta condição pode ser expressa por

$$DN_\lambda = F_1 DN_{\lambda,1} + F_2 DN_{\lambda,2} + \dots + F_N DN_{\lambda,N} + \varepsilon_\lambda \quad (2)$$

onde DN_λ é o número digital de um determinado pixel na banda λ ; F_1, F_2, \dots, F_N são as proporções dos componentes puros no respectivo pixel; $D_{\lambda,1}, \dots, D_{\lambda,N}$ são os componentes puros do respectivo pixel; e ε_λ é o termo de erro.

A equação (1) mais as m possíveis equações (2), totalizam $m + 1$ equações para a solução da AME. Se $m + 1$ for igual ao número de componentes puros, a AME tem solução exata sem o termo de erro. Se $m + 1$ é maior que o número de componentes puros, o erro pode ser estimado por meio do método dos mínimos quadrados. Se $m + 1$ for menor que o número de componentes puros, a AME não apresentará solução única (LILLESAND; KIEFER; CHIPMAN, 2015).

As imagens-fração são produtos gerados pela AME. Elas representam as proporções dos componentes na mistura espectral (MATHER; KOCH, 2011). Normalmente são geradas as imagens-fração vegetação, solo e sombra (ou água), que em geral, são os alvos presentes em qualquer cena terrestre (PONZONI; SHIMABUKURO; KUPLICH, 2012). As imagens-

fração podem ser vistas como uma forma de reduzir a dimensionalidade dos dados, bem como uma forma de realçar as informações de maior interesse (PONZONI; SHIMABUKURO; KUPLICH, 2012; SHIMABUKURO; PONZONI, 2017; ZANOTTA; FERREIRA; ZORTEA, 2019). As imagens-fração têm uma grande variedade de aplicações em diferentes áreas tais como: floresta, agricultura, uso da terra, água, áreas urbanas, entre outras, sendo uma técnica consistente e usual em várias regiões do mundo (PONZONI; SHIMABUKURO; KUPLICH, 2012).

A acurácia do ajuste do modelo de AME é calculada pelo Erro Médio Quadrático (EMQ) (ROTH; DENNISON; ROBERTS, 2012):

$$EMQ = \sqrt{\frac{\sum_{b=1}^k (\epsilon_{\lambda})^2}{k}} \quad (3)$$

Para a solucionar as frações, algumas condições precisam ser estabelecidas: (a) os componentes puros selecionados não devem ser combinação linear dos demais; (b) o número de componentes puros deve ser menor ou igual ao número das bandas espectrais selecionadas; (c) as bandas espectrais não devem estar altamente correlacionadas (LU et al., 2004).

Para um modelo linear de mistura espectral existem dois métodos aplicáveis, isto é, a solução restrita e a solução irrestrita (LU et al., 2004). A solução restrita consiste no cumprimento das seguintes restrições: $\sum_{k=1}^n f_k = 1$ e $0 \leq f_k \leq 1$ (LU et al., 2004).

Na solução irrestrita os valores de f_k podem ser negativos e a soma dos mesmos não contem a restrição de ser igual a 1 (LU et al., 2004). Contudo, os valores da solução irrestrita não refletem as verdadeiras proporções dos componentes puros (LU et al., 2004). Para fins de classificação de uso e cobertura da terra não há diferenças significativas de acurácia entre a solução restrita e a solução irrestrita (LU et al., 2004). No entanto, a redução da correlação entre as imagens tem demonstrado melhorias tanto na estimativa das proporções por meio das frações da AME quanto na acurácia da classificação de uso e cobertura da terra (LU et al., 2004). Dois métodos podem ser usados para a redução da correlação entre as imagens, isto é, Análise por Componentes Principais (APC) ou *Minimum Noise Fraction* (MNF; Fração de mínimo ruído) (LU et al., 2004).

4.4 Metodologia

4.4.1 Área de estudo

Nesta pesquisa, a área de estudo corresponde ao bioma Cerrado com uma área superficial de 2.036.448 km² (IBGE, 2022b). O Cerrado abrange os estados da Bahia (BA), Distrito Federal (DF), Goiás (GO), Maranhão (MA), Mato Grosso (MT), Mato Grosso do Sul (MS), Minas Gerais (MG), Paraná (PR), Piauí (PI), Rondônia (RO), São Paulo (SP), Tocantins (TO), além de áreas disjuntas de Cerrado nos estados do Amapá (AP), Amazonas (AM), Pará (PA) e Roraima (RR) (EMBRAPA, 2022; IBGE, 2022b). No 2020, o Cerrado possuía uma área de pastagens de 48.160.607 ha (MAPBIOMAS, 2021).

Neste estudo, as pastagens são classificadas em N1, N2N3 e N4 (Figura 36), de acordo aos parâmetros definidos por Dias-Filho (2015), conforme a Tabela 13.

Primeiramente, foram coletados 400 pontos em campo (cortesia do Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás - LAPIG), e com o auxílio do *Google Earth*, Sistemas de Informação Geográfica (ArcGIS e QGIS) e de técnicas de fotointerpretação, estes pontos foram multiplicados para um total de 4.212, conforme a Tabela 14.

Tabela 13 – Estádios de Degradação (ED) de pastagens segundo Parâmetros Limitantes, indicadores de Queda na Capacidade de Suporte (QCS), e Nível de Degradação (Nível).

ED	Parâmetro Limitante	QCS (%)	Nível
1	Vigor e solo descoberto	Até 20	Leve (N1)
2	Estádio 1 agravado + plantas invasoras	21 - 50	Moderado (N2)
3	Estádio 2 agravado ou morte das forrageiras (degradação agrícola)	51 - 80	Forte (N3)
4	Solo descoberto + erosão (degradação biológica)	> 80	Muito forte (N4)

Fonte: Adaptado de Dias-Filho, 2015.

Tabela 14 – Informação das amostras de campo.

Nível de Degradação	Nº de pontos de campo	Total	Data de aquisição
N1	1.404		03/2019
N2N3	1.404	4.212	05/2019
N4	1.404		08/2019

Fonte: O autor.

Figura 36 – Níveis das pastagens degradadas.



Legenda: (a) N1 (época úmida). (b) N1 (época seca). (c) N2N3 (época úmida). (d) N2N3 (época seca). (e) N4 (época úmida). (f) N4 (época seca).

Fonte: Cortesia do Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás – LAPIG.

4.4.2 Materiais

Nesta pesquisa foram necessários os seguintes materiais:

- Dados vetoriais (formato shapefile) do Brasil e do Cerrado (IBGE, 2021b);
- 4.212 pontos georreferenciados de pastagens degradadas nos níveis N1, N2N3 e N4 do bioma Cerrado. Os trabalhos de campo foram realizados nos meses de março, maio e agosto de 2019;
- Softwares: QGIS 3 e ArcGIS 10, para a produção de mapas e multiplicação dos 400 pontos originais (cortesia do Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás - LAPIG) para 4.212 pontos; Microsoft Office Excel 2007 e Origin 2022, para elaboração de gráficos;
- Fotos *in situ* (cortesia do Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás - LAPIG);
- *Google Earth Engine*, para o acesso, processamento das imagens digitais e pontos georreferenciados com seus respectivos atributos. No *Google Earth Engine*, Nós também usámos: série temporal Sentinel-2 (2 meses), mapa de uso e cobertura da terra do Brasil do MapBiomas (versão 6) e imagens diárias de precipitação CHIRPS (1 ano).

Figura 37 – Mapa de localização da área de estudo (bioma Cerrado).



Fonte: O autor.

4.4.3 Métodos

4.4.3.1 Multiplicação dos pontos de campo

Inicialmente, foram coletados 400 pontos em campo nas áreas de pastagens (cortesia do Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás - LAPIG), e com o auxílio do *Google Earth*, Sistemas de Informação Geográfica, fotografias de campo (cortesia do LAPIG) e de técnicas de fotointerpretação, estes pontos foram multiplicados para um total de 4.212 com os diferentes níveis de degradação de pastagens já identificados (N1, N2N3 e N4), conforme Figura 41.

A multiplicação dos 400 pontos de campo para os 4.212 pontos foi realizada tanto no *Google Earth*, pela marcação de pontos e extração de polígonos de pastagens, com o auxílio de imagens de satélite de base, quanto em ambiente SIG com o uso de ferramentas de geração de pontos aleatórios no interior dos polígonos de pastagens em formato vetorial coletados no *Google Earth*. Assim, para a multiplicação dos pontos em ambiente SIG, considerando que o tamanho do pixel do Sentinel-2 é de 20m, a distância entre os pontos foi definida considerando o teorema de Pitágoras, em que a distância entre os vértices horizontais e verticais do pixel é de 20m, porém a distância entre os vértices diagonais é $20\sqrt{2}m = 28,28m < 30m$, deste modo, definiu-se a distância mínima entre os pontos igual a 30m, porém, na prática as distâncias foram muito superiores a 30m. O esquema da Figura 43, ilustra as distâncias horizontal, vertical e diagonal de pontos num pixel.

4.4.3.2 Seleção das imagens, bandas espectrais e período de aquisição

Na presente pesquisa, o satélite/sensor mais adequado foi o Sentinel-2/MSI dadas as características das suas resoluções espacial, espectral, temporal e radiométrica, conforme a seção 1.2.1.

Entende-se que quanto maior a resolução espacial da imagem menor a mistura espectral no interior dos pixels, desta forma, para um estudo de Análise de Mistura Espectral este quesito é fundamental. Com uma resolução espacial de 20m o Sentinel-2 apresenta o

potencial de favorecer significativamente a Análise de Mistura Espectral, podendo proporcionar resultados com maior acurácia.

Considerando a grande extensão superficial do bioma Cerrado, é importante que o satélite selecionado tenha alta resolução temporal, devido a cobertura de nuvens, especialmente na estação das chuvas (úmida). Com uma resolução temporal de 5 dias, as imagens do Sentinel-2 apresentam grande capacidade de cobertura de todo o bioma Cerrado tanto na época seca quanto na época úmida.

As características das bandas espectrais do Sentinel-2 apresentam grande potencial em favorecer estudos da vegetação, em especial, o conjunto de imagens da região *red edge* (borda vermelha), isto é, as bandas espectrais B5, B6 e B7, que é uma inovação entre satélites de média resolução espacial. Deste modo, a resolução espectral do Sentinel-2 demonstrou-se ser bastante útil para os objetivos desta pesquisa científica.

Com uma resolução radiométrica equivalente a 12bits (EUROPEAN SPACE AGENCY, 2022b), o Sentinel-2 apresenta grande capacidade de discretizar os alvos terrestres, bem como meio de Processamento Digital de Imagens e inteligência artificial permitir uma melhor identificação das classes de interesse.

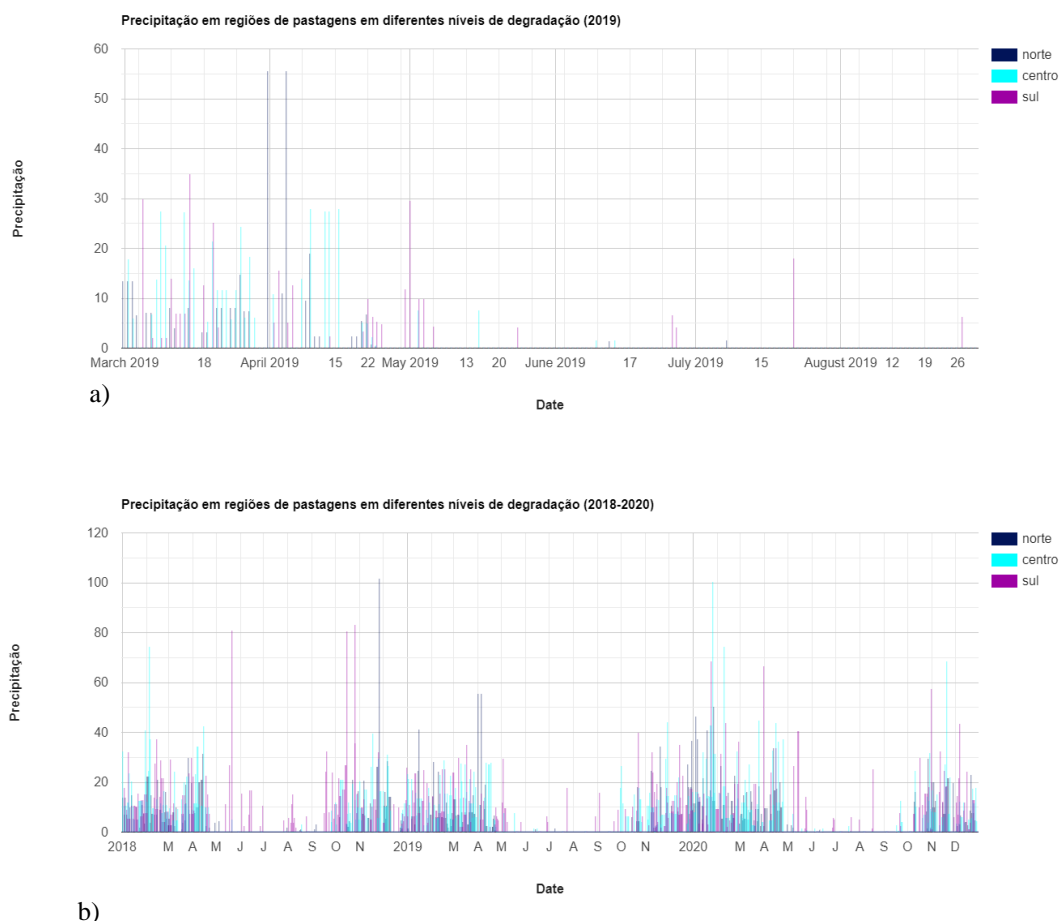
Deste modo, as bandas espectrais selecionadas foram a B2 (azul), B3 (verde), B4 (vermelho), B5 (borda vermelha), B6 (borda vermelha), B7 (borda vermelha), B8 (infravermelho próximo), B11 (infravermelho médio 1), B12 (infravermelho médio 2) (EUROPEAN SPACE AGENCY, 2022a; GOOGLE EARTH ENGINE, 2022a). O motivo da seleção destas bandas espectrais é que as mesmas apresentaram menor Erro Médio Quadrático (EMQ) na Análise de Mistura Espectral (AME), bem como na classificação por *random forest*.

O período de obtenção das imagens (fevereiro, março e agosto de 2019) foi o mais próximo possível do período de coleta dos pontos de campo (março, maio e agosto de 2019) no bioma Cerrado. Para a época úmida, devido a ocorrência de nuvens, as imagens do mês de março não foram suficientes para cobrir todo o Cerrado, desta forma, foram necessárias também imagens do mês de fevereiro. Para a época seca as imagens do mês de agosto foram suficientes para cobrir toda a área de pastagens do bioma Cerrado.

O ciclo das chuvas no Cerrado é bastante similar tanto na parte norte, como na parte central, bem como na parte sul, conforme o gráfico da Figura 38 (a). A época úmida começa em finais de setembro ou início de outubro e termina em maio, já a época seca vai de maio a setembro, conforme a Figura 38 (b). A coleta dos 400 pontos foi realizada em época

chuvosa/úmida (março), em período de transição (maio) e em época seca (agosto), desse modo, a seleção das imagens foi justamente de março a agosto de 2019.

Figura 38 – Ciclo das chuvas do Cerrado.



Legenda: (a) Período de março a agosto de 2019. (b) Período de 2 anos (2018-2020).

Fonte: O autor.

4.4.3.3 Análise de Mistura Espectral (AME)

A Análise de Mistura Espectral (AME) consistiu primeiramente na seleção dos componentes puros característicos do processo de degradação das pastagens. Assim, os componentes puros na AME foram a Vegetação Não Fotossinteticamente Ativa (VNFA), a Vegetação Fotossinteticamente Ativa, o Solo Exposto (SE) e a Sombra/Água. A VNFA pode ser entendida como o material seco das pastagens que já não realiza o processo de

fotossíntese, já a VFA pode ser entendida como o matéria verde das pastagens que realiza o processo de fotossíntese. Quanto ao componente puro Sombra, a sombra e água possuem respostas espectrais muito semelhantes (CAMARA; VALERIANO; VIANEI, 2013), motivo pelo qual o componente puro recebe a denominação de Sombra/Água, e no entanto, torna-se mais prático coletar valores de pixels de corpos de água bem definidos em detrimento de valores de sombras. Quanto ao Solo Exposto, consiste no solo desnudo sem qualquer outro tipo de cobertura. As equações (4), (5) e (6) expressam a AME:

$$\sum_{i=1}^4 F_i = F_1 + F_2 + F_3 + F_4 = 1 \quad (4)$$

$$DN_{\lambda} = F_1 VNFA_{\lambda,1} + F_2 VFA_{\lambda,2} + F_3 SE_{\lambda,3} + F_4 Sombra_{\lambda,4} + \varepsilon_{\lambda} \quad (5)$$

$$EMQ = \sqrt{\frac{\sum_{b=1}^k (\varepsilon_{\lambda})^2}{k}} \quad (6)$$

onde DN_{λ} é o número digital de um determinado pixel na banda λ ; F_1, F_2, F_3, F_4 são as proporções dos componentes puros no respectivo pixel; $VNFA, VFA, SE, Sombra$ são os componentes puros do respectivo pixel; ε_{λ} é o termo de erro; e EMQ é a imagem de Erro Médio Quadrático.


Com a finalidade da obtenção da resposta espectral dos componentes puros, a captura dos valores dos pixels nas diversas bandas espectrais dos mesmos (componentes puros) foi realizada na época mais adequada, isto é, para a VNFA os valores dos pixels nas diversas bandas espectrais foram coletados na época seca (agosto), para a VFA os valores dos pixels nas diversas bandas espectrais foram coletados na época úmida (março), para o SE os valores dos pixels nas diversas bandas espectrais foram coletados na época seca (agosto) e para a Sombra os valores dos pixels nas diversas bandas espectrais foram coletados na época úmida (março). Desta forma, foi possível construir uma biblioteca espectral (VNFA, VFA, SE e Sombra) e aplicá-la em imagens Sentinel-2 tanto da época seca (agosto) quanto da época úmida (de fevereiro a março). A época úmida para a coleta das respostas espectrais (valores dos pixels nas diversas bandas espectrais) dos componentes puros foi apenas o mês de março, na tentativa de coletar a resposta espectral mais pura possível; porém a época úmida para as imagens Sentinel-2, devido a ocorrência de nuvens e a grande extensão superficial do bioma Cerrado, foi definida pelos meses de fevereiro e março.

Figura 39 – Composição de pastagem com a presença de material verde (VFA), material seco (VNFA), solo exposto (SE) e sombra (Sombra).



Fonte: O autor.

Figura 40 – Componentes puros da Análise de Mistura Espectral (AME).



Legenda: (a) Vegetação Fotossinteticamente Ativa (VFA). (b) Vegetação Não-Fotossinteticamente Ativa (VNFA). (c) Solo Exposto (SE). (d) Água/Sombra (Sombra).

Fonte: O autor e cortesia do Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás – LAPIG.

4.5 Processamento Digital de Imagens no *Google Earth Engine*

Nesta pesquisa realizou-se o processamento de uma série temporal de imagens Sentinel-2 (20m) de 3 meses, isto é, tanto na época úmida (fevereiro e março de 2019) quanto na época seca (agosto de 2019), totalizando 3 meses de imagens de todo o bioma Cerrado. As bandas espectrais utilizadas foram: B2 (azul), B3 (verde), B4 (vermelho), B5 (borda vermelha), B6 (borda vermelha), B7 (borda vermelha), B8 (infravermelho próximo), B11

(infravermelho médio 1), B12 (infravermelho médio 2). O período de obtenção das imagens (fevereiro, março e agosto de 2019) foi o mais próximo possível do período de coleta dos pontos de campo (março, maio e agosto de 2019) no Cerrado. Para a época úmida, devido a ocorrência de nuvens, as imagens do mês de março não foram suficientes para cobrir todo o Cerrado, desta forma, foram necessárias também imagens do mês de fevereiro.

O processamento da série temporal Sentinel-2 consistiu, primeiramente, na aplicação de um filtro espacial de remoção de nuvens, de modo a se obter uma série temporal de imagens Sentinel-2 livres de nuvens. Posteriormente, aplicou-se a mediana tanto para a época úmida (mediana1 [fevereiro, março]) quanto para a época seca (mediana2 [Agosto]). Assim, reduziu-se a dimensionalidade da série temporal de imagens Sentinel-2 de todo o bioma Cerrado para apenas 2 imagens medianas, conservou-se as características sazonais das mesmas, e deste modo, tornou-se viável a aplicação da Análise de Mistura Espectral (AME) para todo o bioma Cerrado no *Google Earth Engine*. Para a aplicação da Análise de Mistura Espectral (AME), primeiramente, realizou-se a seleção dos componentes puros VNFA, VFA, SE e Sombra (material verde, material seco, solo exposto e sombra) presentes nas pastagens do Cerrado nos diversos níveis de degradação (N1, N2N3 e N4). Com os componentes puros selecionados foi possível aplicar a Análise de Mistura Espectral (AME) sobre as imagens mediana1 (época úmida) e imagem mediana2 (época seca).

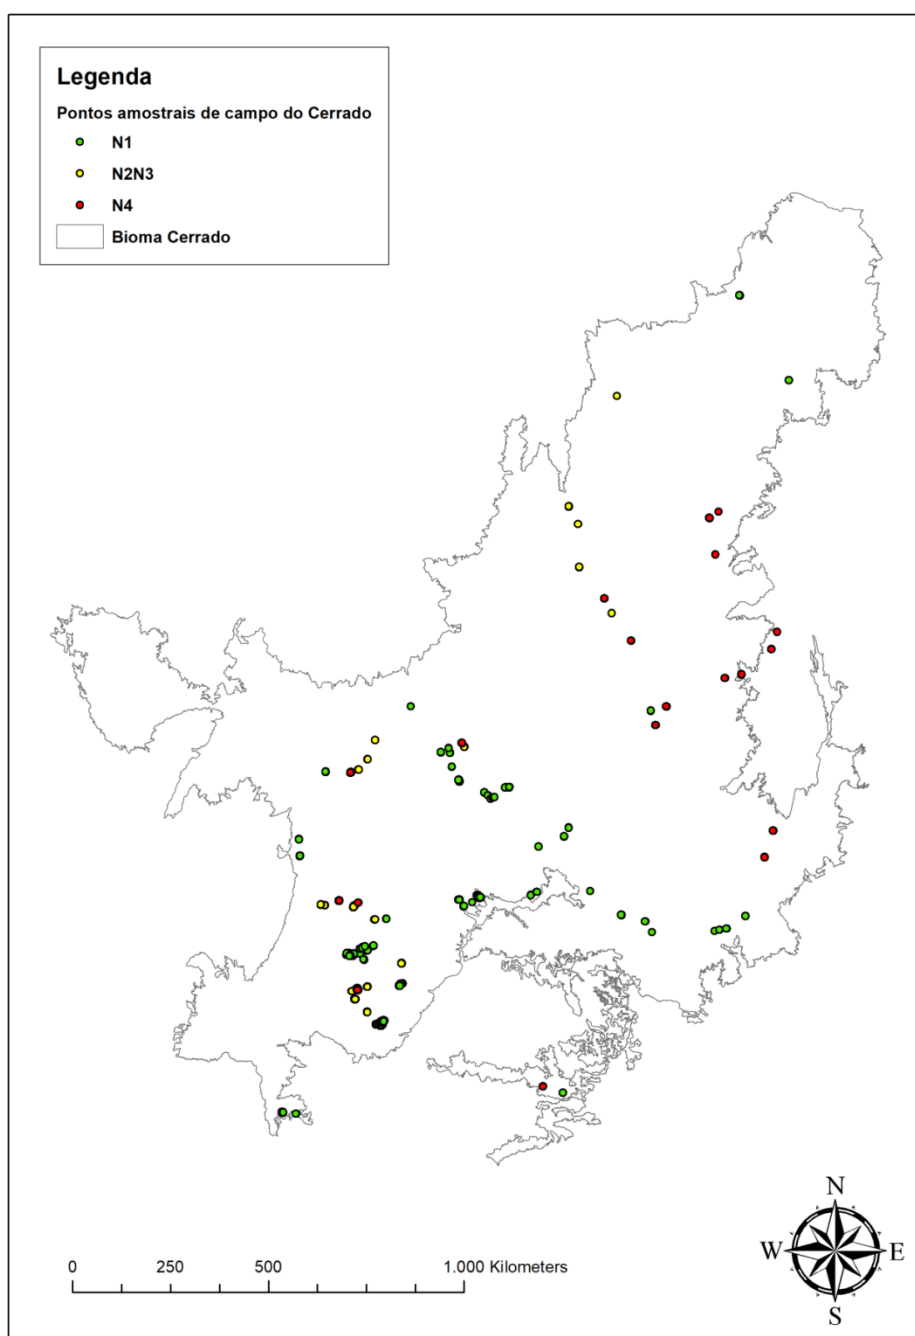
Após o cálculo AME, obtiveram-se 8 imagens-fração, isto é, imagem-fração VNFA, imagem-fração VFA, imagem-fração SE e imagem-fração Sombra de todo o Cerrado, tanto para a época úmida quanto para a época seca, às quais aplicou-se a máscara da área de estudo obtida a partir de um arquivo vetorial e georreferenciado do Cerrado (IBGE, 2021b) e a máscara das áreas de pastagens – mapa de uso e cobertura da terra do MapBiomas versão 6, cujos pixels de pastagens correspondem ao valor 15 (MAPBIOMAS, 2021) –, obtendo-se assim um cubo de pixels contendo apenas as áreas de pastagens do bioma Cerrado.

Em seguida, com o cubo de pixels das áreas de pastagens e os 70% das amostras de campo, efetuou-se o processo de classificação de imagens digitais com base no algoritmo de aprendizado de máquina *random forest*, empregando 500 árvores de decisão, o que resultou em uma imagem classificada nas 3 classes correspondentes aos níveis de degradação de pastagens: N1, N2N3 e N4.

Uma vez obtida a imagem classificada, realizou-se a validação da mesma com base nos 30% restantes das amostras de campo. Durante a validação foi realizado um controle estatístico e avaliação da acurácia da imagem classificada. Valores de Índice *Kappa*, Acurácia Global, Acurácia do Produtor, Acurácia do Usuário e *F-score* a partir de 0.7 correspondem a

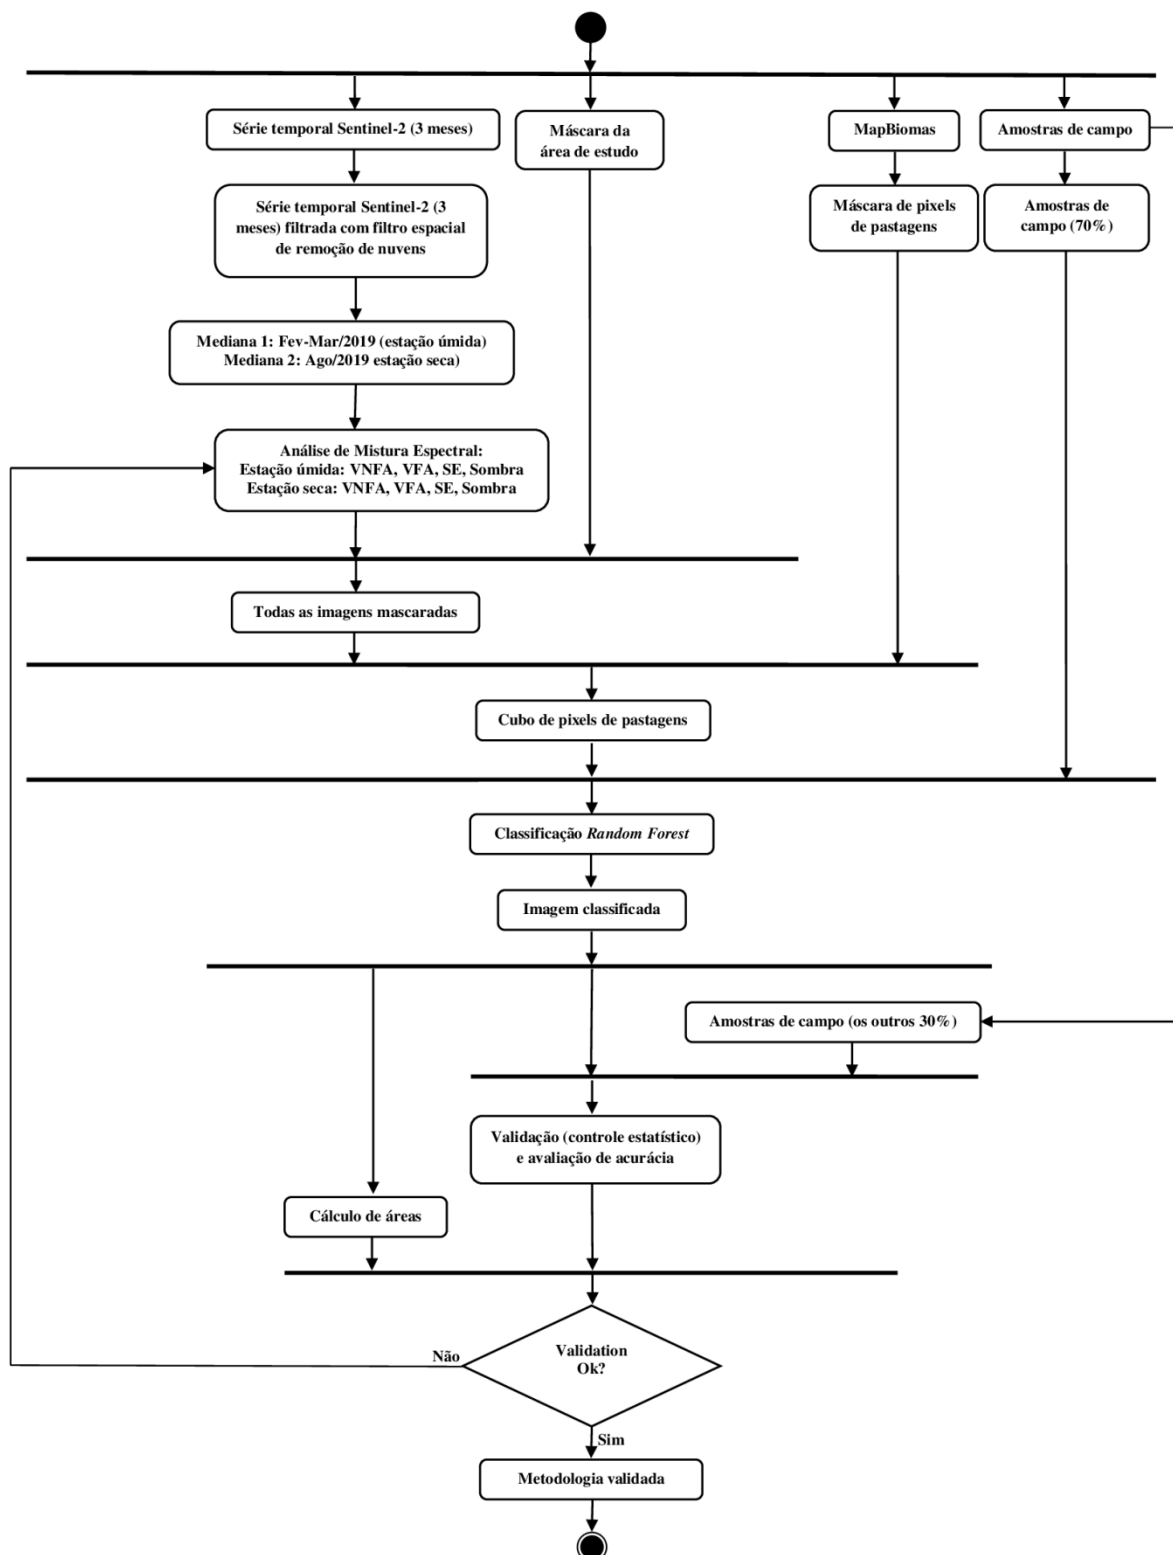
valores satisfatórios. Quando a validação é satisfatória, todos os resultados obtidos são definitivos. No caso de validação não satisfatória, é necessário redefinir a seleção dos componentes puros e/ou redefinir as bandas espectrais usadas na AME, conforme a Figura 42, de modo a se alcançar resultados satisfatórios (metodologia validada).

Figura 41 – Distribuição espacial dos 4.212 pontos de pastagens usados no presente estudos com a identificação dos seus respectivos níveis de degradação.



Fonte: O autor.

Figura 42 – Fluxograma da metodologia proposta.

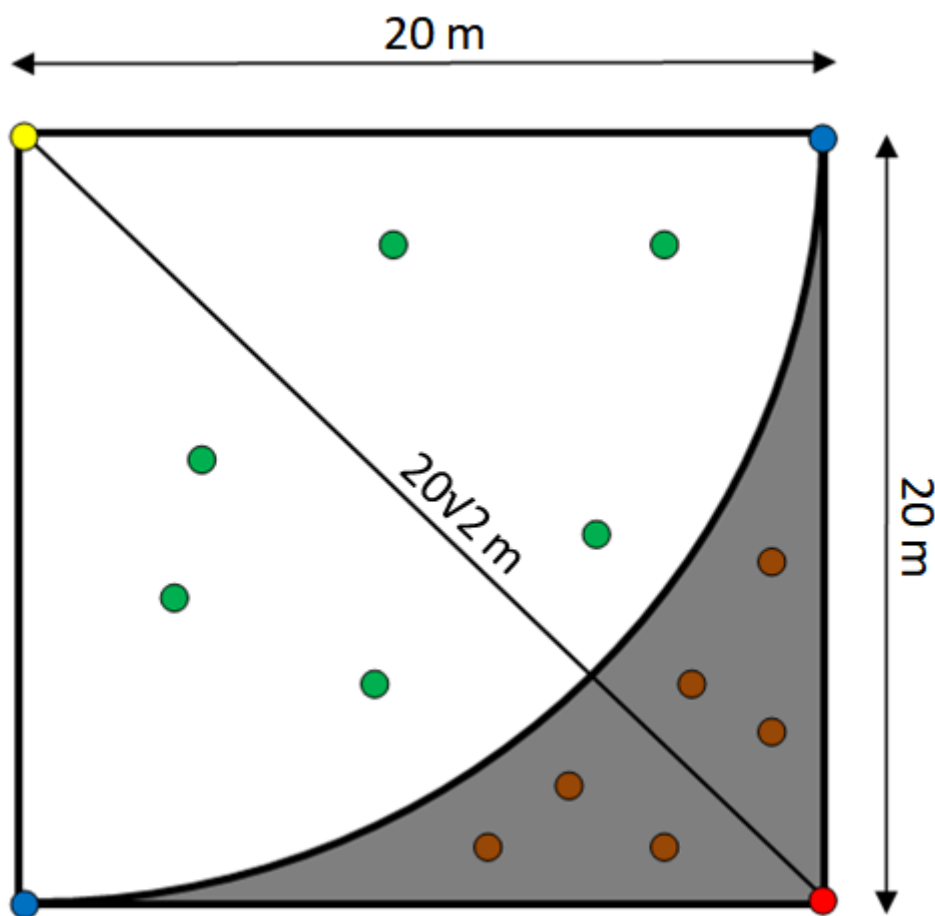


Fonte: O autor.

Na Figura 43 apresenta-se um esquema de pontos no interior de um pixel. As distâncias horizontais e verticais entre pontos nos vértices do pixel são de 20m, já a distância

diagonal é de $20\sqrt{2}m \cong 30m$. Os pontos verdes estão a uma distância inferior a 20m do ponto amarelo. Os pontos azuis estão a uma distância de exatamente 20m do ponto amarelo. Os pontos laranjas estão a uma distância superior a 20m do ponto amarelo. O ponto vermelho está a uma distância de $20\sqrt{2}m \cong 30m$ do ponto amarelo. A distância diagonal deve ser considerada como critério de distância mínima entre os pontos quando se pretende gerar pontos únicos no interior dos pixels em análise.

Figura 43 – Distanciamento entre pontos no interior de um pixel.



Fonte: O autor.

4.6 Resultados e discussões

A aplicação da metodologia proposta no presente estudo proporcionou diversos resultados que serão apresentados e discutidos a seguir. Com base no uso de uma série temporal de imagens Sentinel-2 de todo o bioma Cerrado; com o período de aquisição de imagens correspondente à época úmida (fevereiro e março) e à época seca (agosto) do ano de 2019, sendo compatível com o período de coleta dos pontos em campo (março, maio e agosto); a remoção de pixels afetados por nuvens; a aplicação de mediana para a época úmida (mediana1) e mediana para a época seca (mediana2); o cálculo da Análise de Mistura Espectral (AME); e a aplicação das máscaras das áreas de interesse foi possível a obtenção de um cubo de pixels de pastagens que, com os 4.212 pontos de campo, foi classificado pelo método *random forest*, dando como resultado a imagem classificada das áreas de pastagens do bioma Cerrado, conforme a Figura 48.

O processamento de um volume de dados tão grande, compatível com a extensão superficial do Cerrado, bem como o correspondente em termos de pixels com resolução espacial de 20m, em um período de tempo relativamente curto, só foi possível graças ao *Google Earth Engine*.


No presente estudo utilizou-se imagens Sentinel-2 corrigidas atmosféricamente, conforme pode-se observar na Figura 44 onde as curvas espectrais dos componentes puros estão caracterizadas, pois expressam valores de valores de reflectância de superfície. Deste modo, é possível observar as diferenças entre as curvas espectrais dos componentes puros presentes na Análise de Mistura Espectral, bem como a grande semelhança que ocorre entre as curvas espectrais VNFA e SE.

Da Análise de Mistura Espectral (AME) surgiram as imagens-fração VNFA, VFA, SE e Sombra tanto para a época úmida quanto para a época seca, mais duas imagens de Erro Médio Quadrático (EMQ) de cada época, totalizando 10 imagens. As imagens EMQ têm a utilidade de permitirem o controle da qualidade da AME, isto é, se a seleção dos componentes puros foi bem sucedida ou não, podendo assumir valores no intervalo [0,1].

O modelo empregado na AME ajusta quando os valores dos pixels das imagens-fração estão limitados no intervalo [0,1]. Deste modo, observou-se que somente com a aplicação da AME o modelo não ajustou, pois houve ocorrência de muitos valores negativos para a imagem-fração VNFA e muitos valores acima de 1 para a imagem-fração SE, ademais observou-se correlação de 0,807 e 0,679 entre os valores de VNFA e SE respectivamente nas

épocas úmida e seca, conforme a Figura 45 (a) e a Figura 45 (b). Deste modo, Lu et al. (2004) afirmam que nestes casos é necessário a aplicação da Análise por Componentes Principais (ACP) antes da Análise de Mistura Espectral (AME), para reduzir a correlação entre as imagens originais e garantir melhores resultados na AME, permitindo que o modelo ajuste, ou seja, os valores estejam no intervalo [0,1]. Assim, aplicou-se a ACP e posteriormente a AME, e desta forma o modelo teve um melhor ajustamento para a época úmida, conforme Figura 46 (a), no entanto, alguns pontos (principalmente pastagens degradadas em N4) ainda permaneceram com valores negativos de VNFA. Para a época seca, mesmo após a aplicação da ACP e AME ainda obtiveram-se muitos valores fora do intervalo [0,1], conforme Figura 46 (b), e desta forma, descartou-se a estimativa das proporções dos componentes puros na época seca. Na ACP as bandas espectrais usadas foram as mesmas, isto é, B2, B3, B4, B5, B6, B7, B8, B11 e B12, resultando em 9 imagens de componentes principais. No entanto, utilizou-se apenas os 5 primeiros principais componentes – o primeiro principal componente contém a maior variância do conjunto de dados, sendo que os principais componentes subsequentes vão tendo um decréscimo de variância do conjunto de dados (JENSEN, 2016; LILLESAND; KIEFER; CHIPMAN, 2015; MATHER; KOCH, 2011; ZANOTTA; FERREIRA; ZORTEA, 2019) –, considerando que a AME é composta por 4 componentes puros, e o número de imagens na AME não pode ser inferior ao número de componentes puros; além disso, existe o interesse de determinar o EMQ, por isso foi necessário selecionar mais um principal componente, caso contrário a solução seria exata ($EMQ = 0$). Por conseguinte, foi possível determinar as proporções dos componentes puros nas imagens-fração da época úmida para os diferentes níveis de degradação de pastagens, conforme o diagrama ternário da Figura 47. Após a aplicação da ACP e AME, o EMQ ficou estabelecido entre 0,001 e 0,03.

Figura 44 – Curvas do comportamento espectral dos componentes puros VNFA, VFA, SE e Sombra com base nas bandas espectrais selecionadas do Sentinel-2 (B2, B3, B4, B5, B6, B7, B8, B11 e B12).



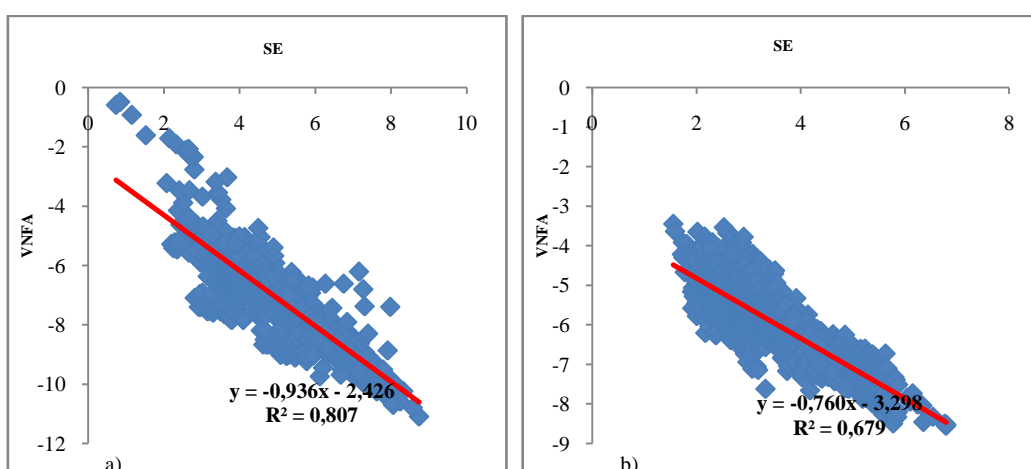
Fonte: O autor.

O *Google Earth Engine* limita em até 1.000.000.000 de pixels alguns processamentos, como é o caso da ACP, deste modo, não foi possível aplicar a ACP para todo o bioma Cerrado, sendo possível aplicar apenas para algumas áreas de teste. No entanto, Lu et al. (2004) afirmam que não observaram diferenças significativas de acurácia relativamente a classificação de uso e cobertura da terra tanto para a solução com restrição quanto para a solução sem restrição, e tanto para imagens corrigidas atmosféricamente quanto para imagens não corrigidas atmosféricamente. Deste modo, para a classificação *random forest* de todo o bioma Cerrado aplicou-se a solução sem restrição da AME, conforme abordado na seção 4.3 (Análise de Mistura Espectral).

Nas áreas de teste, apesar da aplicação da ACP, observou-se que a correlação entre VNFA e SE persistiu, o que demonstra que as imagens Sentinel-2 têm uma certa limitação em separar o material seco (VNFA) do solo exposto (SE), embora o Sentinel-2 tenha sido indicado como sendo uma possível oportunidade para a estimativa de VNFA, conforme Li and Guo (2016). Desta forma, para a estimativa e avaliação das proporções dos componentes

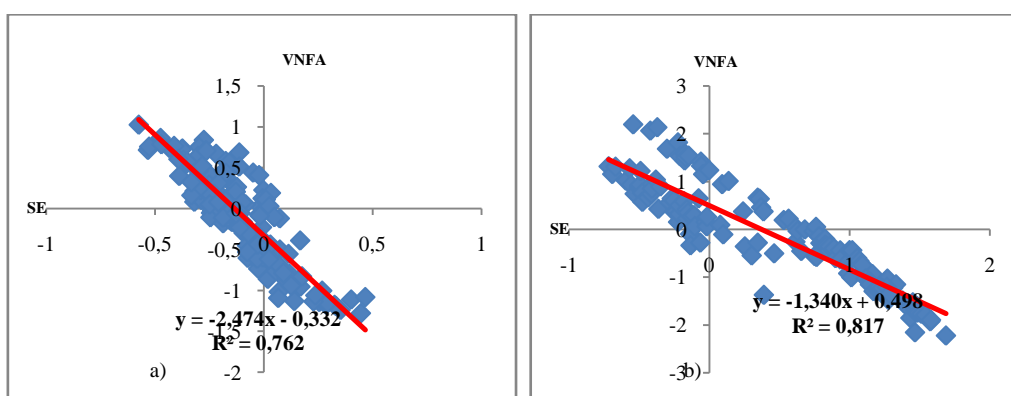
puros existentes nos diferentes níveis de degradação das pastagens realizou-se a soma das imagens VNFA e SE, isto é, VNFA+SE, conforme Numata et al. (2007). Assim, foi possível determinar as proporções dos componentes puros em cada nível de degradação das pastagens e construir um modelo conceitual com base no diagrama ternário da Figura 47. Deste modo, observa-se que o Sentinel-2 tem potencial de separar satisfatoriamente os componentes puros VNFA+SE, VFA e Sombra por meio da AME, expressando as proporções destes componentes puros nos diferentes níveis de degradação das pastagens (N1, N2N3 e N4).

Figura 45 – Correlação entre VNFA e SE com valores oriundos da AME.




Legenda: (a) Época úmida. (b) Época seca.
Fonte: O autor.

Figura 46 – Correlação entre VNFA e SE com valores oriundos da ACP, e posteriormente, AME.



Legenda: (a) Época úmida. (b) Época seca.
Fonte: O autor.

Figura 47 – Diagrama ternário dos níveis de degradação das pastagens do Cerrado baseado em frações de AME (modelo conceitual).



Fonte: O autor.

As proporções de VNFA+SE, VFA e Sombra para os níveis de degradação de pastagens N1, N2N3 e N4, conforme Figura 47, expressam que no bioma Cerrado as pastagens mais vigorosas (N1) tendem a apresentar a proporção ($VNFA+SE < 25\%$; $VFA > 50\%$; $Sombra < 25\%$), já as pastagens moderadamente degradadas (N2N3) tendem a apresentar a proporção ($VNFA+SE \leq 25\%$; $40\% < VFA < 60\%$; $30\% < Sombra < 40\%$) e as pastagens mais degradadas (N4) tendem a apresentar a proporção ($VNFA+SE > 60\%$; $VFA < 40\%$; $Sombra \leq 30\%$). Deste modo, quanto maior a proporção de VFA maior a produtividade das pastagens; e quanto maior a proporção de VNFA+SE maior a degradação das pastagens. A Sombra é um bom indicador da altura das pastagens, corroborando com Numata et al. (2007), também é um bom indicador da altura de espécies invasoras, razão pela qual áreas de pastagens N2N3 apresentam maior valor de Sombra, conforme as Figura 36 (c), Figura 36 (d) e Figura 47.

Tabela 15 – Controle da acurácia da classificação *random forest*.

Série temporal (2019)	Nível de Degradação	Acurácia do Produtor	Acurácia do Usuário	F-score	Acurácia Global	Kappa
Estação úmida (Fev, Mar)	N1	0.79	0.81	0.80	0.75	0.63
	N2N3	0.76	0.70	0.73		
	N4	0.71	0.77	0.74		
Estação seca (Ago)	N1	0.78	0.80	0.79	0.76	0.64
	N2N3	0.78	0.74	0.76		
	N4	0.72	0.75	0.73		
Estação seca (Fev, Mar) +	N1	0.90	0.88	0.89	0.86	0.79
	N2N3	0.89	0.83	0.86		
Estação úmida (Ago) OBS.: Os melhores valores	N4	0.79	0.88	0.83		

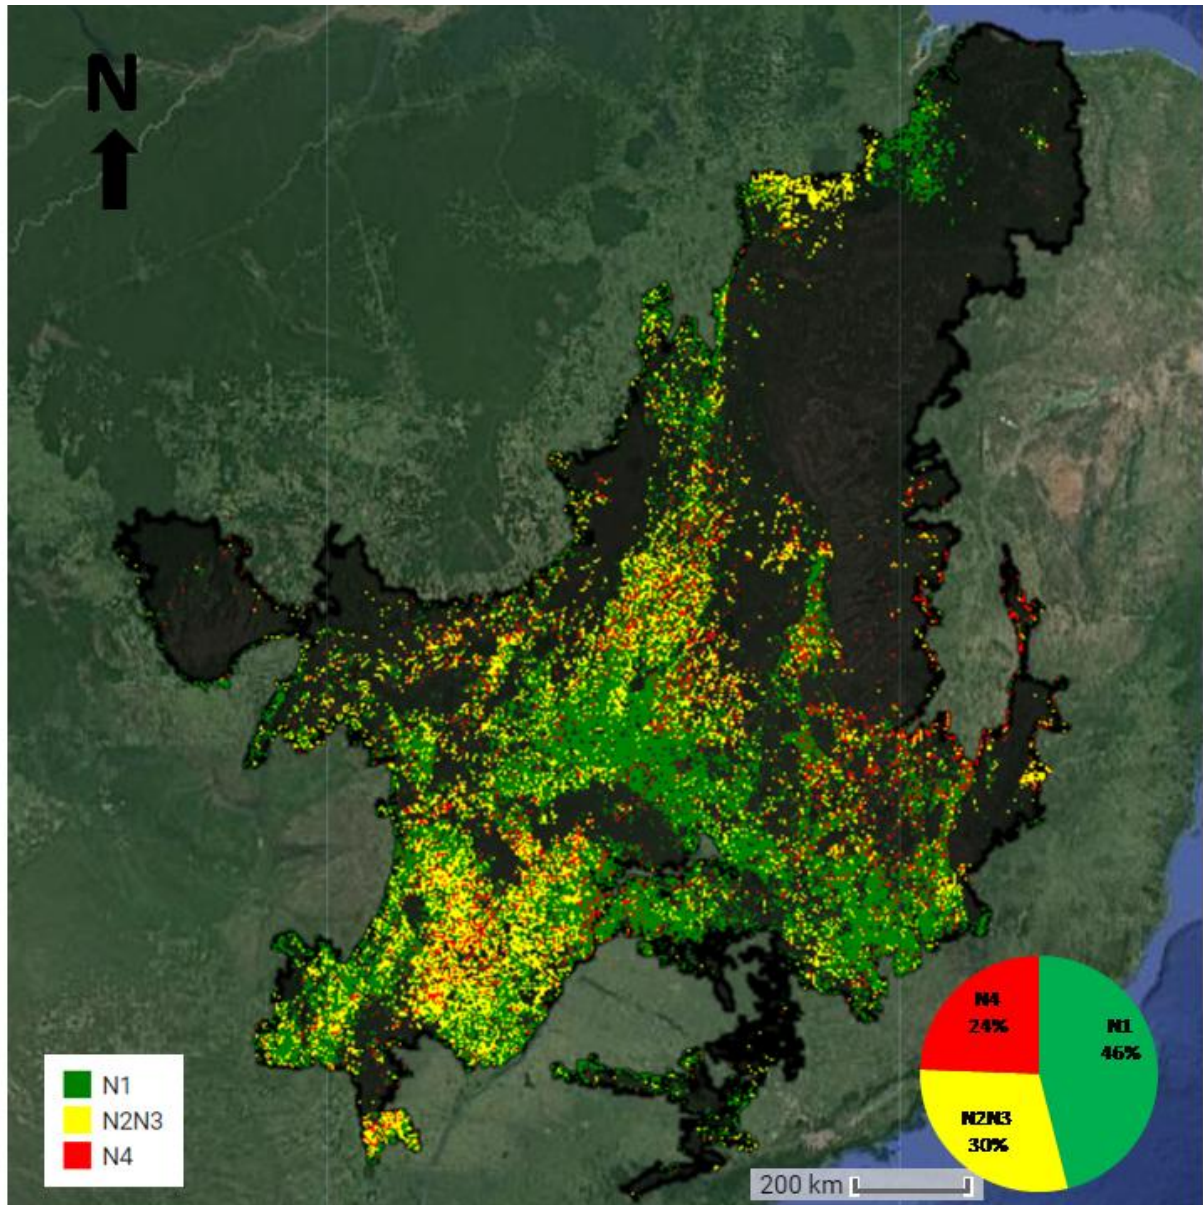
Fonte: O autor.

A análise da acurácia, conforme a Tabela 15, apresenta os seguintes resultados: AG = 0.86, K = 0.79 e *F-score* (N1 = 0.89; N2N3 = 0.86; N4 = 0.83), os quais podem ser avaliados como relevantes e significativos.

A obtenção das estatísticas de controle de qualidade, bem como a classificação dos diferentes níveis de degradação das pastagens de todo o bioma Cerrado só foi possível graças ao *Google Earth Engine* que é um ambiente computacional e poderosa ferramenta de processamento digital de imagens e sensoriamento remoto, sendo bastante robusto, alcançando alta velocidade de processamento, permitindo o processamento de grandes volumes de dados, realizando computação paralela e computação em nuvem, e dispondo de algoritmos de inteligência artificial e aprendizado de máquina, tal como o *random forest*.

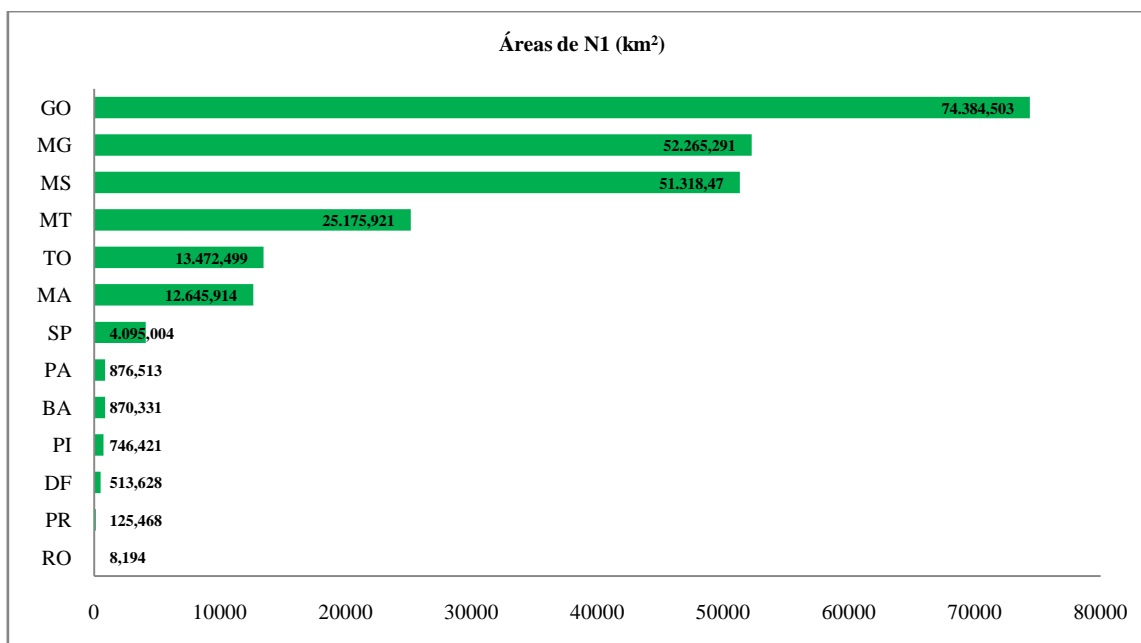
A partir da classificação dos diferentes níveis de degradação das pastagens do Cerrado foi possível extrair diversas estatísticas que dão uma melhor percepção do processo de degradação das pastagens a nível dos estados do bioma Cerrado.

Figura 48 – Mapa dos níveis de degradação das pastagens do bioma Cerrado.



Fonte: O autor.

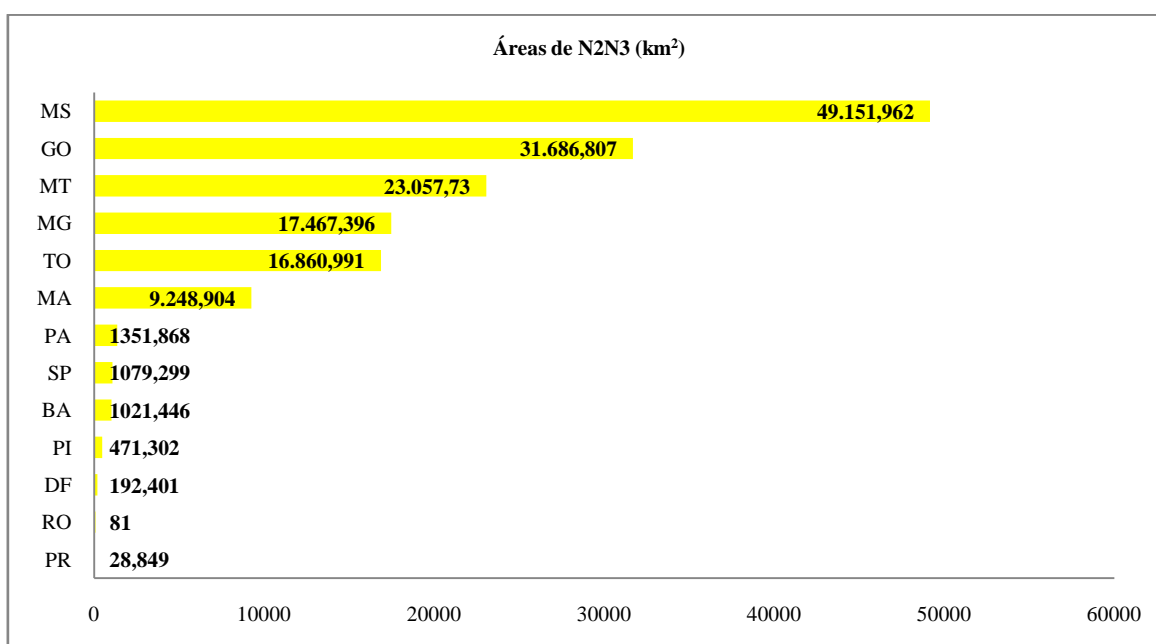
Figura 49 – Áreas de pastagens bem conservadas no nível N1 por estados do Cerrado.



Fonte: O autor.

Entre os principais estados que possuem as pastagens mais vigorosas (N1) e melhor conservadas no nível N1, em ordem de importância, são: GO, MG, MS, MT, TO e MA com áreas de pastagens bem conservadas acima dos 12.000 km², conforme a Figura 49.

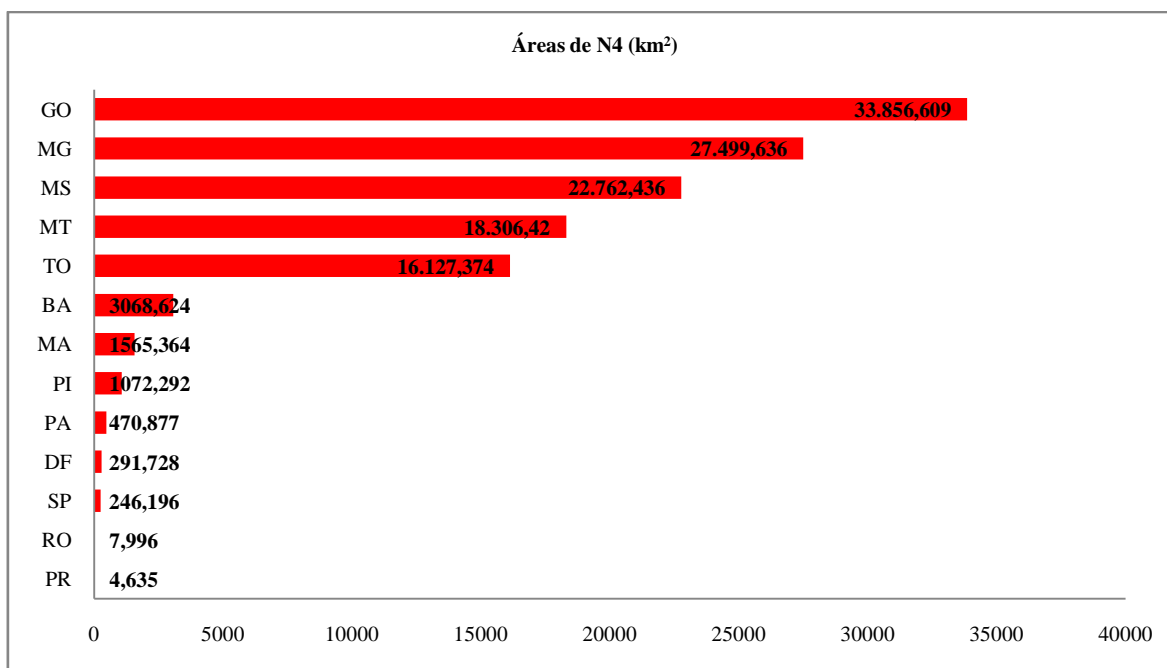
Figura 50 – Áreas de pastagens degradadas no nível N2N3 por estados do Cerrado.



Fonte: O autor.

Os principais estados com pastagens degradadas no nível N2N3, em ordem de importância, são: MS, GO, MT, MG, TO e MA com quase cerca de 9.000 km² de pastagens degradadas, conforme a Figura 50.

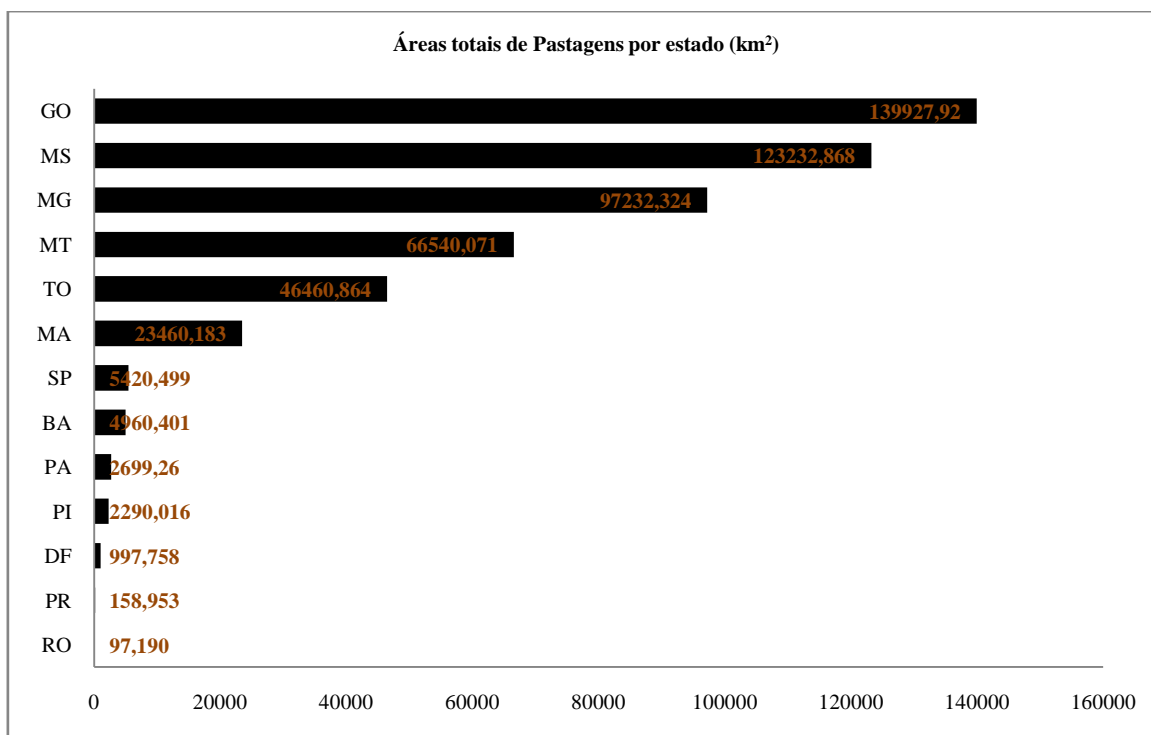
Figura 51 – Áreas de pastagens degradadas no nível N4 por estados do Cerrado.



Fonte: O autor.

Entre os principais estados com mais pastagens degradadas no nível N4, em ordem de importância, temos: GO, MG, MS, MT e TO, com áreas de pastagens degradadas acima de 15.000 km², conforme Figura 51.

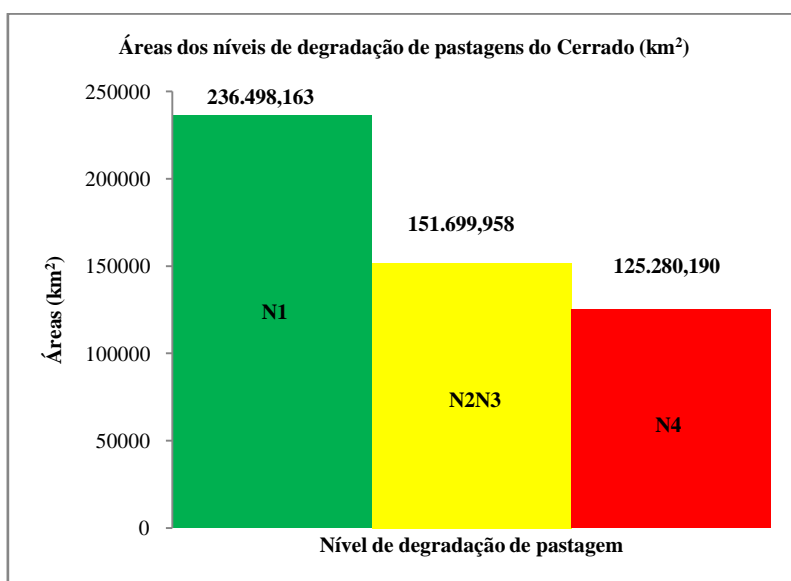
Figura 52 – Áreas totais de pastagens por estados do Cerrado.



Fonte: O autor.

De uma forma geral, os principais estados que mais possuem pastagens (N1+N2N3+N4), em ordem de importância, são: GO, MS, MG, MT, TO, MA, com áreas acima de 20.000 km² de pastagens. Uma análise completa das pastagens do Cerrado por estado é apresentada na Figura 52.

Figura 53 – Gráfico de áreas de pastagens totais do Cerrado.



Fonte: O autor.

O bioma Cerrado como um todo possui as seguintes estatísticas de áreas e percentagens de pastagens totais: N1 (236.498,163 km²; 46%), N2N3 (151.699,958 km²; 30%) e N4 (125.280,190 km²; 24%); totalizando cerca de 513.478,312 km², conforme Figura 53. Deste modo, nossos estudos indicam que cerca de 54% das pastagens do Cerrado estão degradadas. Estes resultados corroboram com os estudos da Embrapa (2014) que afirmam que mais da metade das pastagens do Cerrado estão em algum estágio de degradação.

Dada a importância do Cerrado para o setor agropecuário no Brasil (bioma com a maior produção agropecuária) os resultados são bastante preocupantes. Assim, é fundamental o incentivo, aplicação e fortalecimento de políticas públicas de recuperação de pastagens para o Cerrado, tal como o Programa Agricultura de Baixo Carbono (ABC) e intensificação de sistemas de produção, tal como os sistemas de integração Lavoura-Pecuária-Floresta (iLPF), principalmente para os estados mais afetados com o processo de degradação de pastagens (GO, MG, MS, MT e TO), para o incentivo de ações regionais e locais. Os resultados obtidos nesta pesquisa científica apresentam consistências com os resultados nos estudos de Pereira et al. (2018).

Li and Guo (2016) e Numata et al., (2008) afirmam que sensores hiperespectrais têm demonstrado superioridade em relação aos sensores multiespectrais em estudos de estimativa de VNFA. Um índice hiperespectral muito útil é o CAI que sendo cruzado com o NDVI dá origem ao triângulo CAI-NDVI num espaço de atributos 2D, possibilitando a separação dos componentes puros VNFA, VFA e SE, conforme estudos de Guerschman et al., (2009). No entanto, na presente pesquisa científica, o Sentinel-2 (sensor multiespectral) apesar das suas limitações possibilitou a estimativa das proporções dos componentes puros VNFA+SE, VFA e Sombra nos diferentes níveis de degradação de pastagens do Cerrado (N1, N2N3 e N4), bem como a classificação *random forest* de todo o bioma Cerrado com acurácia satisfatória com base nos componentes puros VNFA, VFA, SE e Sombra.

A presente metodologia se mostrou eficaz, eficiente e robusta, permitindo alcançar com sucesso o objetivo proposto na presente pesquisa científica, isto é, identificar, monitorar e mapear a qualidade das pastagens/níveis de degradação das pastagens de todo o bioma Cerrado.

4.7 Conclusões

1 - Para fins de estimativa das proporções VNFA, VFA, SE e Sombra:

- Com base nas bandas espectrais puras selecionadas do Sentinel-2 (B2, B3, B4, B5, B6, B7, B8, B11 e B12) e na Análise de Mistura Espectral (AME) por si só o modelo não ajustou, havendo ocorrência de muitos valores negativos de VNFA e muitos valores de SE acima de 1, tanto para a época úmida quanto para a época seca. Porém, com a aplicação da Análise por Componentes Principais (ACP) antes da Análise de Mistura Espectral (AME), houve um melhor ajustamento do modelo para a época úmida, pois apenas cerca de 5% dos valores de VNFA e SE nas áreas de teste ficaram fora do intervalo [0,1]. Já para a época seca houve persistência de muitos valores fora do intervalo de [0,1], e dessa forma, para fins de estimativa de proporções de VNFA, VFA, SE e Sombra, os resultados da época seca foram descartados.
- A aplicação da ACP permitiu alcançar a solução com restrição na AME, ou seja, a grande maioria dos valores das imagens-fração (VNFA, VFA, SE e Sombra) estarem limitados no intervalo [0,1]. As imagens-fração (VNFA, VFA, SE e Sombra), oriundas da solução com restrição, permitiram a estimativa das proporções dos componentes puros (VNFA+SE, VFA e Sombra) para os diferentes níveis de degradação de pastagens, isto é, para N1 (VNFA+SE < 25%; VFA > 50%; Sombra < 25%), para N2N3 (VNFA+SE ≤ 25%; 40% < VFA < 60%; 30% < Sombra < 40%) e para N4 (VNFA+SE > 60%; VFA < 40%; Sombra ≤ 30%).
- Os valores de VNFA e SE apresentaram forte correlação tanto antes da aplicação da ACP ($R^2 = 0,807$) quanto após a aplicação da ACP ($R^2 = 0,762$), o que demonstrou que o Sentinel-2 tem limitações na separação espectral destas duas classes. As curvas espectrais VNFA e SE também se apresentaram muito semelhantes.
- O sensor MSI/Sentinel-2 apresentou limitações para separar espectralmente a VNFA e o SE. Deste modo, não foi possível realizar a estimativa da proporção VNFA isoladamente. Contudo, devido a semelhança

entre as respostas espectrais de VNFA e SE foi possível usar a combinação VNFA+SE que, por sua vez, se mostrou bastante útil no presente estudo.

- VNFA+SE é um bom indicador da degradação das pastagens. Já VFA é um bom indicador da produtividade das pastagens. E finalmente, Sombra é um bom indicador da altura da pastagem e/ou altura de espécies invasoras.

2 - Com base na classificação *random forest*:

- As imagens-fração de Vegetação Não-Fotossinteticamente Ativa (VNFA), Vegetação Fotossinteticamente Ativa (VFA), Solo Exposto (SE) e Sombra, da época úmida e da época seca em conjunto, se mostraram ser eficientes na classificação *random forest* dos níveis de degradação de pastagens do bioma Cerrado, alcançando a acurácia de AG = 0.83, K = 0.75 e F-score (N1 = 0.88; N2N3 = 0.83; N4 = 0.80), os quais podem ser avaliados como relevantes e significativos. Estes resultados são oriundos da solução sem restrição da AME, em que os valores das imagens-fração podem estar fora do intervalo [0,1], apresentando resultados satisfatórios e corroborando com outros estudos citados ao longo desta pesquisa científica.
- Nossos estudos indicam que cerca de 54% das pastagens do bioma Cerrado estão degradadas, corroborando com um estudo da Embrapa que afirma que mais de metade das pastagens degradadas do Cerrado se encontram em algum estágio de degradação.
- Com base na classificação dos diferentes níveis de degradação de pastagens de todo o bioma Cerrado foi possível extrair informações úteis, tais como os estados com as maiores taxas de pastagens degradadas do Cerrado, isto é, GO, MG, MS, MT e TO. Desse modo, é possível incentivar, aplicar e fortalecer políticas públicas de recuperação de pastagens degradadas do Cerrado, como o Programa Agricultura de Baixo Carbono (ABC) e a intensificação de sistemas de produção como os sistemas de integração Lavoura-Pecuária-Floresta (iLPF), a níveis regional e local, entre outras medidas.

3 - O Google Earth Engine foi fundamental no processamento digital de imagens e na classificação dos diferentes níveis de degradação das pastagens de todo o bioma Cerrado na presente pesquisa, devido a sua capacidade de processar volumosos conjuntos de dados, alta velocidade de processamento, processamento em nuvem, computação paralela, inteligência

artificial e aprendizado de máquina, tal como o algoritmo *random forest*, se mostrando ser bastante robusto, eficiente e eficaz no presente estudo.

4 - Sendo o Cerrado o bioma com a maior produção agropecuária do Brasil, o cenário apresentado no presente estudo é bastante preocupante, sendo necessário a aplicação de medidas de recuperação das pastagens degradadas para o aumento de produtividade de carne, bem como os benefícios advindos da integração Lavoura-Pecuária-Floresta (iLPF).

5 - O objetivo da presente pesquisa científica foi alcançado, isto é, a metodologia proposta desempenhou com sucesso a função de identificar, monitorar e mapear os diferentes níveis de degradação das pastagens do Cerrado (N1, N2N3 e N4) com base em técnicas de Sensoriamento Remoto e Processamento Digital de Imagens.

CONCLUSÕES GERAIS

Em relação à primeira metodologia apresentada no capítulo 2:

O índice de vegetação de maior importância indicado durante o processo de classificação *random forest* foi o CRI1 (*Carotenoid Reflectance Index 1*), porém por si só, não foi capaz de garantir uma acurácia satisfatória na separabilidade dos diferentes níveis de degradação das pastagens (N1, N2N3 e N4), sendo necessário adicionar outros produtos de sensoriamento remoto, como bandas puras do Sentinel-2 e Sentinel-1, outros índices de vegetação, texturas e SRTM. Contudo, usando apenas uma série temporal de imagens Sentinel-2 de 1 ano nas bandas B2, B3, B4, B5, B6, B7, B8, B11 e B12 já foi possível alcançar resultados satisfatórios de acurácia AG = 0.96, K = 0.94 e F-score (N1 = 0.97; N2N3 = 0.97; N4 = 0.94). O índice CRI1 também foi o que apresentou maior correlação com todas as características biofísicas das pastagens (peso da biomassa verde, altura da biomassa e peso da biomassa morta), alcançando maior correlação com o peso da biomassa verde $R^2 = 0.759$. A altura da pastagem e o material seco também apresentaram correlação forte com o CRI1, cujos valores foram $R^2 = 0.745$ e $R^2 = 0.729$, respectivamente.

Quanto à maior acurácia alcançada na classificação *random forest* com todos os produtos de Sensoriamento Remoto utilizados e os dados de campo os valores foram os seguintes: AG = 0.96, K = 0.94 e F-score (N1 = 0.97; N2N3 = 0.97; N4 = 0.94). As fórmulas gerais da metodologia são: $(S2 + VI^* + Textura_{18} + VV + Slope)$ e $(S2 + VI^* + Textura_{18} + VH + Slope)$.

Em relação ao capítulo 3:

A metodologia proposta neste capítulo foi uma simplificação da metodologia proposta no capítulo anterior, devido às grandes extensões superficiais do bioma Cerrado, sendo necessário ajustar a metodologia original de modo que se tornasse possível mapear e avaliar a qualidade de grandes extensões de áreas de pastagens do Cerrado nos seus diversos níveis de degradação (N1, N2N3 e N4). Deste modo, a acurácia alcançada no processo de classificação foi AG = 0.94, K = 0.91 e F-score (N1 = 0.94, N2N3 = 0.94, N4 = 0.94). A simplificação consistiu em aplicação de mediana mensal na série temporal, redução dos índices de vegetação e texturas aplicadas na metodologia original. A fórmula geral da metodologia simplificada é $(S2 + VI)$.

Em relação a capítulo 4:

Aqui houve duas metas. A primeira foi mapear e avaliar a qualidade das pastagens nos seus diferentes níveis de degradação (N1, N2N3 e N4) e a segunda foi realizar a estimativa das proporções de material verde (Vegetação Fotossinteticamente Ativa, VFA, ou *Photosynthetic Vegetation*, PV), material seco (Vegetação Não Fotossinteticamente Ativa, VNFA, ou *Non-Photosynthetic Vegetation*, NPV), solo exposto (SE ou *Bare Soil*, BS) e sombra (Sombra ou *Shade*) com base nas imagens-fração de mesmo nome obtidas por meio de Análise de Mistura Espectral (AME). Deste modo, a acurácia na classificação *random forest* das imagens-fração e pontos de campo foi: AG = 0.83, K = 0.75 e F-score (N1 = 0.88; N2N3 = 0.83; N4 = 0.80). É importante ressaltar que estes resultados são relativos tanto à época úmida (março) quanto à época seca (agosto), isto é, (época úmida + época seca).

Quanto à estimativa das proporções VNFA, VFA, SE e Sombra por meio da AME, as imagens Sentinel-2 apresentaram certas limitações na estimativa do material seco (VNFA) isoladamente, devido à sua similaridade espectral com o solo exposto, sendo necessário analisar as duas variáveis em conjunto, isto é, (VNFA+SE) pois claramente, uma estava interferindo na outra, pelo fato de ambas apresentarem sinais opostos e correlação muito forte tanto na época chuvosa quanto na época seca. Desse modo, foi necessário aplicar a Análise por Componentes Principais (ACP) antes da AME, para reduzir a correlação entre as bandas puras. Este procedimento permitiu que o modelo da AME ajustasse melhor, com boa parte dos valores dentro do intervalo [0,1]. Alguns pontos permaneceram com valores negativos de VNFA (principalmente pastagens degradadas em N4). Deste modo, as estimativas foram as seguintes: N1 (VNFA+SE < 25%; VFA > 50%; Sombra < 25%), N2N3 (VNFA+SE ≤ 25%; 40% < VFA < 60%; 30% < Sombra < 40%) e N4 (VNFA+SE > 60%; VFA < 40%; Sombra ≤ 30%).

Comparando as 3 metodologias propostas, séries temporais mais extensas (metodologia do capítulo 2) tendem a proporcionar maior acurácia em algoritmos de aprendizado de máquina, como o *random forest*, comparativamente a séries temporais menores (metodologia do capítulo 3). A classificação *random forest* por meio das bandas puras das imagens Sentinel-2 e Sentinel-1, índices de vegetação, texturas e SRTM aplicadas em Valença/RJ (metodologia do capítulo 2), e até mesmo a versão mais simplificada aplicada no Cerrado (metodologia do capítulo 3), apresentaram maior acurácia do que a classificação *random forest* por meio das imagens-fração VNFA, VFA, SE e Sombra aplicada no Cerrado (metodologia do capítulo 4).

Finalmente, a hipótese da presente tese de doutorado foi corroborada, bem como os objetivos gerais e específicos, com a ressalva de que não foi possível estimar isoladamente a

componente VNFA por meio do Sentinel-2, pois apesar das oportunidades e vantagens disponibilizadas pelas suas bandas espectrais, em comparação com outros sensores multiespectrais, certos artigos científicos têm demonstrado que é necessário o uso de dados hiperespectrais.

REFERÊNCIAS

- AASE, J. K.; TANAKA, D. L. Reflectances from four wheat residue cover densities as influenced by three soil backgrounds. **Agronomy Journal**, v. 83, n. 4, p. 753–757, 1991.
- AGUIAR, D. A. et al. MODIS time series to detect anthropogenic interventions and degradation processes in tropical pasture. **Remote Sensing**, v. 9, n. 1, p. 1–20, 2017.
- AMAZON ENVIRONMENTAL RESEARCH INSTITUTE. Brazil's "Low-Carbon Agriculture" Program: Barriers to Implementation. **Amazon Environmental Research Institute**, p. 1–6, 2012.
- ARAGÃO, A. A. et al. **Dinâmica agrícola no Cerrado: Análises e projeções**. 1. ed. Brasília: Embrapa, 2020.
- ARAÚJO, E. A. DE. **Degradação De Pastagens Na Amazônia Ocidental: Avaliação e alternativas de recuperação**. 1. ed. Rio Branco, AC: Clube de Autores, 2011.
- ASNER, G. P. Biophysical and biochemical sources of variability in canopy reflectance. **Remote Sensing of Environment**, v. 64, n. 3, p. 234–253, 1998.
- ASNER, G. P. et al. Ecosystem structure along bioclimatic gradients in Hawai'i from imaging spectroscopy. **Remote Sensing of Environment**, v. 96, n. 3–4, p. 497–508, 2005.
- ASNER, G. P.; BORGHI, C. E.; OJEDA, R. A. Desertification in Central Argentina: Changes in ecosystem carbon and nitrogen from imaging spectroscopy. **Ecological Applications**, v. 13, n. 3, p. 629–648, 2003.
- ASNER, G. P.; HEIDEBRECHT, K. B. Spectral unmixing of vegetation, soil and dry carbon cover in arid regions: Comparing multispectral and hyperspectral observations. **International Journal of Remote Sensing**, v. 23, n. 19, p. 3939–3958, 2002.
- ASNER, G. P.; LOBELL, D. B. A biogeophysical approach for automated SWIR unmixing of soils and vegetation. **Remote Sensing of Environment**, v. 74, n. 1, p. 99–112, 2000.
- BIOTA DE ORTHOPTERA DO BRASIL. **Mata Atlântica**. Disponível em: <<http://www.orthoptera.com.br/pt-BR/bioma/mata-atlantica>>. Acesso em: 20 jun. 2022a.
- BIOTA DE ORTHOPTERA DO BRASIL. **Cerrado**. Disponível em: <<http://www.orthoptera.com.br/pt-BR/bioma/cerrado>>. Acesso em: 20 jun. 2022b.
- BIRTH, G. S.; MCVEY, G. R. Measuring the Color of Growing Turf with a Reflectance Spectrophotometer is grown primarily. p. 2–5, 1968.
- BISWAL, B. Carotenoid catabolism during leaf senescence and its control by light. **Journal of Photochemistry and Photobiology, B: Biology**, v. 30, n. 1, p. 3–13, 1995.

- BLASCHKE, T.; KUX, H. **Sensoriamento Remoto e SIG Avançados: novos sistemas sensores, métodos inovadores**. São Paulo, SP: Oficina de Textos, 2007.
- BODDEY, R. M. et al. Nitrogen cycling in Brachiaria pastures: The key to understanding the process of pasture decline. **Agriculture, Ecosystems and Environment**, v. 103, n. 2, p. 389–403, 2004.
- BRAZ, S. P. et al. **Degradação de pastagens, matéria orgânica do solo e a recuperação do potencial produtivo em sistemas de baixo “input” tecnológico na região dos cerrados**. [s.l: s.n.].
- BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.
- BREIMAN, L.; CUTLER, A. **Random forests**. Disponível em: <https://www.stat.berkeley.edu/~breiman/RandomForests/cc_home.htm>. Acesso em: 14 out. 2021.
- BROGE, N. H.; LEBLANC, E. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. **Remote Sensing of Environment**, v. 76, n. 2, p. 156–172, 2001.
- CAMARA, G.; VALERIANO, D.; VIANEI, J. **Metodologia para o Cálculo da Taxa Anual de Desmatamento na Amazônia Legal**. São Jose dos Campos Instituto Nacional de Pesquisas Espaciais (INPE), , 2013. Disponível em: <http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes/pdfs/metodologia_taxa_pr_odes.pdf>
- CAO, X. et al. Developing a MODIS-based index to discriminate dead fuel from photosynthetic vegetation and soil background in the Asian steppe area. **International Journal of Remote Sensing**, v. 31, n. 6, p. 1589–1604, 2010.
- CERRI, C. C. et al. Brazilian greenhouse gas emissions: the importance of agriculture and livestock. **Sci. Agric**, v. 66, n. December, p. 831–843, 2009.
- CHÁVEZ, R. O. et al. Assessing water stress of desert tamarugo trees using in situ data and very high spatial resolution remote sensing. **Remote Sensing**, v. 5, n. 10, p. 5064–5088, 2013.
- CHOI, H.; JEONG, J. Speckle noise reduction technique for sar images using statistical characteristics of speckle noise and discrete wavelet transform. **Remote Sensing**, v. 11, n. 10, 2019.
- CHRISTOPHERSON, R. W. **Geossistemas: Uma Introdução à Geografia Física**. 7. ed. Porto Alegre, RS: Bookman, 2012.
- CLAUSI, D. A. An analysis of co-occurrence texture statistics as a function of grey level quantization. **Canadian Journal of Remote Sensing**, v. 28, n. 1, p. 45–62, 2002.

CLEVERS, J. G. P. W. Imaging Spectrometry in Agriculture - Plant Vitality And Yield Indicators. **Imaging Spectrometry — a Tool for Environmental Observations**, n. January 1970, p. 193–219, 1994.

CNA. **PIB do Agronegócio alcança participação de 26,6% no PIB brasileiro em 2020 | Confederação da Agricultura e Pecuária do Brasil (CNA)**. Disponível em: <https://www.cnabrazil.org.br/boletins/pib-do-agronegocio-alcanca-participacao-de-26-6-no-pib-brasileiro-em-2020#_ftn1>. Acesso em: 22 mar. 2022a.

CNA. **Panorama do Agro | Confederação da Agricultura e Pecuária do Brasil (CNA)**. Disponível em: <<https://www.cnabrazil.org.br/cna/panorama-do-agro>>. Acesso em: 22 mar. 2022b.

CONNERS, R. W.; TRIVEDI, M. M.; HARLOW, C. A. Segmentation of a high-resolution urban scene using texture operators (Sunnyvale, California). **Computer Vision, Graphics, & Image Processing**, v. 25, n. 3, p. 273–310, 1984.

COSME, A. **Projeto em Sistemas de Informação Geográfica**. 1. ed. Lisboa: Lidel, 2012.

CRIST, E. P.; KAUTH, R. J. The Tassled Cap de-mystified. **Photogrammetric Engineering & Remote Sensing**, v. 52, n. 1, p. 81–86, 1986.

CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. 1. ed. Campinas,SP: IG/UNICAMP, 1992.

DAUGHTRY, C. S. T. et al. Measuring crop residue cover using remote sensing techniques. **Theoretical and Applied Climatology**, v. 54, n. 1–2, p. 17–26, 1996.

DAUGHTRY, C. S. T. et al. Remote sensing the spatial distribution of crop residues. **Agronomy Journal**, v. 97, n. 3, p. 864–871, 2005.

DAUGHTRY, C. S. T. et al. Remote sensing of crop residue cover and soil tillage intensity. **Handbook of Environmental Chemistry, Volume 5: Water Pollution**, v. 91, n. 1–2, p. 101–108, 2006.

DAUGHTRY, C. S. T.; HUNT, E. R.; MCMURTREY, J. E. Assessing crop residue cover using shortwave infrared reflectance. **Remote Sensing of Environment**, v. 90, n. 1, p. 126–134, 2004.

DAVIDSON, E. A. et al. Objective indicators of pasture degradation from spectral mixture analysis of landsat imagery. **Journal of Geophysical Research: Biogeosciences**, v. 114, n. 1, p. 1–7, 2009.

DELEGIDO, J. et al. A red-edge spectral index for remote sensing estimation of green LAI over agroecosystems. **European Journal of Agronomy**, v. 46, p. 42–52, 2013.

DEMMIG-ADAMS, B.; GILMORE, A. M.; III, W. W. A. In vivo functions of carotenoids in

higher plants. **The FASEB Journal**, v. 10, n. 4, p. 403–412, 1996.

DETMANN, E. et al. **Métodos para análise de alimentos**. 1. ed. [s.l.] INCT, 2012.

DIAS-FILHO, M. B. **Competição e sucessão vegetal em pastagens**. In: PEREIRA, O. G., OBEID, J. A., FONSECA, D. M., JÚNIOR, D. N. **2º Simpósio sobre manejo estratégico da pastagem, Viçosa: UFV, pp. 251-287.** , 2004.

DIAS-FILHO, M. B. **Recuperação de pastagens e segurança alimentar: uma abordagem histórica da pecuária na Amazônia**. 1. ed. Bebedouro, SP: [s.n.].

DIAS-FILHO, M. B. **Diagnóstico das Pastagens no BrasilEmbrapa Amazônia Oriental**. Belém: [s.n.]. Disponível em: <www.cpatu.embrapa.br/publicacoes_online>.

DIAS-FILHO, M. B. **Degradação de pastagens: processos, causas e estratégias de recuperação**. 4. ed. [s.l.] Embrapa Amazônia Oriental, 2015.

DIAS-FILHO, M. B.; ANDRADE, C. M. S. **Pastagens no trópico úmido**. Belém: [s.n.].

DINGAAN, M. N. V.; TSUBO, M. Improved assessment of pasture availability in semi-arid grassland of South Africa. **Environmental Monitoring and Assessment**, v. 191, n. 12, 2019.

DUSSEUX, P. et al. Monitoring of grassland productivity using Sentinel-2 remote sensing data. **International Journal of Applied Earth Observation and Geoinformation**, v. 111, n. May, p. 102843, jul. 2022.

ECKARD, R. J.; GRAINGER, C.; DE KLEIN, C. A. M. Options for the abatement of methane and nitrous oxide from ruminant production: A review. **Livestock Science**, v. 130, n. 1–3, p. 47–56, 2010.

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

EMBRAPA. **GeoDegrade**. Disponível em: <<http://www.geodegrade.cnpm.embrapa.br/apresentacao>>. Acesso em: 18 jun. 2022a.

EMBRAPA. **Materiais e Métodos - GeoDegrade**. Disponível em: <<http://www.geodegrade.cnpm.embrapa.br/metodos>>. Acesso em: 18 jun. 2022b.

EMBRAPA. **Soluções tecnológicas. Geodegrade webgis**. Disponível em: <<https://www.embrapa.br/busca-de-solucoes-tecnologicas/-/produto-servico/2505/geodegrade-webgis>>. Acesso em: 6 fev. 2018.

EMBRAPA. **Embrapa mapeia degradação das pastagens do Cerrado - Portal Embrapa**. Disponível em: <<https://www.embrapa.br/busca-de-noticias/-/noticia/2361250/embrapa-mapeia-degradacao-das-pastagens-do-cerrado>>. Acesso em: 22 mar. 2022a.

EMBRAPA. **GeoDegrade - Desenvolvimento de geotecnologias para identificação e monitoramento de níveis de degradação em pastagens**. Disponível em:

<<https://www.embrapa.br/busca-de-projetos/-/projeto/37897/geodegrade---desenvolvimento-de-geotecnologias-para-identificacao-e-monitoramento-de-niveis-de-degradacao-em-pastagens>>. Acesso em: 18 jun. 2022b.

EMBRAPA. Geoabc: Metodologias e Inovações Tecnológicas para o Monitoramento e o Planejamento da Agricultura de Baixa Emissão de Carbono em apoio à Governança do Plano ABC - Portal Embrapa. Disponível em: <<https://www.embrapa.br/busca-de-projetos/-/projeto/212388/geoabc-metodologias-e-inovacoes-tecnologicas-para-o-monitoramento-e-o-planejamento-da-agricultura-de-baixa-emissao-de-carbono-em-apoio-a-governanca-do-plano-abc>>. Acesso em: 8 set. 2022.

EMBRAPA. Bioma Cerrado - Portal Embrapa. Disponível em: <<https://www.embrapa.br/contando-ciencia/bioma-cerrado>>. Acesso em: 22 mar. 2022.

ESA. ESA - About the launch. Disponível em: <https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2/About_the_launch>. Acesso em: 19 jun. 2022a.

ESA. Sentinel-2 - Resolution and Swath . Disponível em: <<https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2/instrument-payload/resolution-and-swath>>. Acesso em: 19 jun. 2022b.

ESA. Sentinel-2 images the globe every 5 days. Disponível em: <https://sentinels.copernicus.eu/web/sentinel/news/-/asset_publisher/xR9e/content/sentinel-2-images-the-globe-every-5-days;jsessionId=91FBAABF384E5D2E1307781094455441.jvm2?redirect=https%3A%2F%2Fsentinels.copernicus.eu%2Fweb%2Fsentinel%2Fnews%3Bjsessionid%3D91FBAABF384E5D2E1307781094455441.jvm2%3Fp_p_id%3D101_INSTANCE_xR9e%26p_p_lifecycle%3D0%26p_p_state%3Dnormal%26p_p_mode%3Dview%26p_p_col_id%3Dcolumn-1%26p_p_col_count%3D1%26_101_INSTANCE_xR9e_keywords%3D%26_101_INSTANCE_xR9e_advancedSearch%3Dfalse%26_101_INSTANCE_xR9e_delta%3D70%26_101_INSTANCE_xR9e_andOperator%3Dtrue>. Acesso em: 19 jun. 2022c.

ESA. Sentinel-2: Spatial Resolutions. Disponível em: <<https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/resolutions/spatial>>. Acesso em: 19 jun. 2022d.

ESA. ESA - Sentinel-1. Disponível em: <https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-1>. Acesso em: 20 jun. 2022e.

ESA. Sentinel-1 SAR: Level-2. Disponível em:

<<https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-1-sar/product-types-processing-levels/level-2>>. Acesso em: 21 jun. 2022f.

ESA. **Sentinel-1 SAR: Acquisition Modes**. Disponível em: <<https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-1-sar/acquisition-modes>>.

Acesso em: 21 jun. 2022g.

ESA. **Sen2Cor**. Disponível em: <<https://step.esa.int/main/snap-supported-plugins/sen2cor/>>.

Acesso em: 21 ago. 2022h.

EUROPEAN SPACE AGENCY. **Sentinel Online: MultiSpectral Instrument (MSI) Overview**. Disponível em: <<https://sentinel.esa.int/web/sentinel/technical-guides/sentinel-2-msi/msi-instrument>>. Acesso em: 9 jun. 2022a.

EUROPEAN SPACE AGENCY. **Sentinel-2: Radiometric resolutions**. Disponível em:

<<https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/resolutions/radiometric>>. Acesso em: 9 jun. 2022b.

FAO. **REDD+ Reducing Emissions from Deforestation and Forest Degradation | Food and Agriculture Organization of the United Nations**. Disponível em: <<http://www.fao.org/redd/en/>>. Acesso em: 3 out. 2021.

FAO. Food and Agriculture Organization of the United Nations (FAO). In: **Food and Agriculture Organization of the United Nations. The state of food and agriculture: Livestock in the balance**. [s.l.: s.n.].

FERREIRA, N. J. **Aplicações ambientais brasileiras dos satélites NOAA e TIROS-N**. 1. ed. São Paulo, SP: Oficina de Textos, 2004.

FILHO, C.; MONTEIRO, F. A.; CORSI, M. Recuperação de pastagens degradadas de Braquiária decumbens. 1.Efeito de diferentes tratamentos de fertilização e manejo. **Revista Pasturas Tropicales**, v. 14, p. 2–6, 1992.

FITZ, P. R. **Geoprocessamento sem complicação**. 1. ed. São Paulo, SP: Oficina de Textos, 2008.

FOLEY, J. A. et al. Solutions for a cultivated planet. **Nature**, v. 478, n. 7369, p. 337–342, 2011.

FONSECA, A. D.; FERNANDES, J. C. **Detecção remota**. 1. ed. Lisboa: LIDEL, 2004.

FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento remoto em Agricultura**. 1. ed. São Paulo, SP: Oficina de Textos, 2017.

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

GERBER, P. et al. Policy options in addressing livestock's contribution to climate change.

Animal, v. 4, n. 3, p. 393–406, 2010.

GITELSON, A. A. et al. Assessing Carotenoid Content in Plant Leaves with Reflectance Spectroscopy. **Photochemistry and Photobiology**, v. 75, n. 3, p. 272, 2002.

GOMES, M. P. et al. **Desafios do cerrado: como sustentar a expansão da produção com produtividade e competitividade**. São Paulo: Associação Mato-grossense dos Produtores de Algodão, 2016.

GONZALEZ, R. C.; WOODS, R. E. **Processamento digital de imagens**. 3. ed. São Paulo, SP: Pearson Educación, 2010.

GOOGLE EARTH ENGINE. **Sentinel-2 MSI: MultiSpectral Instrument, Level-1C | Earth Engine Data Catalog | Google Developers**. Disponível em: <https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2#bands>.

Acesso em: 9 jun. 2022a.

GOOGLE EARTH ENGINE. **Sentinel-1 SAR GRD: C-band Synthetic Aperture Radar Ground Range Detected, log scaling | Earth Engine Data Catalog | Google Developers**. Disponível em: <https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S1_GRD#description>. Acesso em: 19 jun. 2022b.

GORGENS, E. B.; SILVA, A. G. P. DA; RODRIGUEZ, L. C. E. **LIDAR: Aplicações florestais**. 1. ed. Curitiba, PR: EDITORA CRV, 2014.

GOVERNMENT OF THE FEDERATIVE REPUBLIC OF BRAZIL. Intended Nationally Determined Contribution: Towards achieving the objective of the United Nations Framework Convention on Climate Change. **Intended Nationally Determined Contribution**, v. 9, p. 6, 2015.

GOVERNMENT OF THE FEDERATIVE REPUBLIC OF BRAZIL. **Paris Agreement Brazil's Nationally Determined Contribution (NDC)**. [s.l.: s.n.]. Disponível em: <[https://www4.unfccc.int/sites/ndcstaging/PublishedDocuments/Brazil First/Brazil First NDC \(Updated submission\).pdf](https://www4.unfccc.int/sites/ndcstaging/PublishedDocuments/Brazil%20First/Brazil%20First%20NDC%20(Updated%20submission).pdf)>.

GOWARD, S. N.; HUENNRICH, K. F.; WARING, R. H. Visible-near infrared spectral reflectance of landscape components in western Oregon. **Remote Sensing of Environment**, v. 47, n. 2, p. 190–203, 1994.

GUERRA, A. J. T.; JORGE, M. DO C. O. **Processos erosivos e recuperação de áreas degradadas**. 1. ed. São Paulo, SP: Oficina de Textos, 2017.

GUERSCHMAN, J. P. et al. Estimating fractional cover of photosynthetic vegetation, non-photosynthetic vegetation and bare soil in the Australian tropical savanna region upscaling the EO-1 Hyperion and MODIS sensors. **Remote Sensing of Environment**, v. 113, n. 5, p. 928–

945, 2009.

GUO, L. et al. Relevance of airborne lidar and multispectral image data for urban scene classification using Random Forests. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 1, p. 56–66, 2011.

HARALICK, R. M.; DINSTEIN, I.; SHANMUGAM, K. Textural Features for Image Classification. **IEEE Transactions on Systems, Man and Cybernetics**, v. SMC-3, n. 6, p. 610–621, 1973.

HILL, M. J. Vegetation index suites as indicators of vegetation state in grassland and savanna: An analysis with simulated SENTINEL 2 data for a North American transect. **Remote Sensing of Environment**, v. 137, p. 94–111, 2013.

HOTT, M. C. et al. Analysis of grassland degradation in Zona da Mata, MG, Brazil, based on NDVI time series data with the integration of phenological metrics. **Remote Sensing**, v. 11, n. 24, 2019.

HUETE, A. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. v. 83, p. 195–213, 2002.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, 1988.

HUETE, A. R. MODIS vegetation index algorithm theoretical basis v3. **Environmental Sciences**, n. Mod 13, 1999.

IBGE. **Censo demográfico 2010**. Disponível em: <<https://ww2.ibge.gov.br/home/estatistica/populacao/censo2010/default.shtm>>.

IBGE. **IBGE | Projeção da população**. Disponível em: <https://www.ibge.gov.br/apps/populacao/projecao/index.html?utm_source=portal&utm_medium=popclock&utm_campaign=novo_popclock>. Acesso em: 5 out. 2021a.

IBGE. **Downloads** | **IBGE**. Disponível em: <<https://www.ibge.gov.br/geociencias/downloads-geociencias.html>>. Acesso em: 8 nov. 2021b.

IBGE. **Áreas Territoriais** | **IBGE**. Disponível em: <<https://www.ibge.gov.br/geociencias/organizacao-do-territorio/estrutura-territorial/15761-areas-dos-municipios.html?=&t=o-que-e>>. Acesso em: 18 mar. 2022c.

IBGE. **Biomás brasileiros** | **Educa** | **Jovens** - **IBGE**. Disponível em: <<https://educa.ibge.gov.br/jovens/conheca-o-brasil/territorio/18307-biomass-brasileiros.html>>. Acesso em: 18 mar. 2022a.

IBGE. **IBGE | Brasil em síntese | território**. Disponível em:

<<https://brasilemsintese.ibge.gov.br/territorio.html>>. Acesso em: 18 mar. 2022b.

ICMBIO. ICMBIO - Centro Nacional de Pesquisa e Conservação da Biodiversidade do Cerrado e Caatinga - Biodiversidade. Disponível em:

<<https://www.icmbio.gov.br/cbc/conservacao-da-biodiversidade/biodiversidade.html>>.

Acesso em: 20 jun. 2022.

INPE. SOS Mata Atlântica e INPE lançam novos dados do Atlas do bioma. Disponível em: <http://www.inpe.br/noticias/noticia.php?Cod_Noticia=5115>. Acesso em: 20 jun. 2022.

INPE, N. I. FOR S. R. Perguntas Frequentes. Disponível em: <<http://www.inpe.br/faq/index.php?pai=6>>. Acesso em: 4 nov. 2021.

IPCC. Assessment Report 6 Climate Change 2021: The Physical Science Basis. 2021.

JAKIMOW, B. et al. Mapping pasture management in the Brazilian Amazon from dense Landsat time series. [s.l.: s.n.]. v. 205

JENSEN, J. R. Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres. 2. ed. São José dos Campos, SP: Parêntese Editora, 2011.

JENSEN, J. R. Introductory Digital Image Processing: A Remote Sensing Perspective. 4. ed. South Carolina: Pearson Education, 2016.

JIANG, Z. et al. Remote Sensing of Environment Development of a two-band enhanced vegetation index without a blue band. v. 112, p. 3833–3845, 2008.

JONES, M. B.; DONNELLY, A. Carbon sequestration in temperate grassland ecosystems and the influence of management, climate and elevated CO₂. *New Phytologist*, v. 164, n. 3, p. 423–439, 2004.

KAUTH, R. J. Tasseled Cap - a Graphic Description of the Spectral-Temporal Development of Agricultural Crops As Seen By Landsat. p. 41–51, 1976.

KAUTH, R. J. et al. Feature extraction applied to agricultural crops as seen by Landsat. Technical description of the Large Area Crop Inventory Experiment (LACIE): The LACIE Symposium, October 23 to 26, 1978, NASA Johnson Space Center/sponsored by National Aeronautics and Space Administration, Lyndon B. Johnson Space Center, United States Dep. **Anais...**1979.

KELLIHER, F. M.; CLARK, H. Ruminants. [s.l.] Routledge, 2010.

LEE, J. SEN. Speckle analysis and smoothing of synthetic aperture radar images. *Computer Graphics and Image Processing*, v. 17, n. 1, p. 24–32, 1981.

LI, X. et al. Comparison of methods for estimating fractional cover of photosynthetic and non-photosynthetic vegetation in the otindag sandy land using GF-1 wide-field view data. *Remote Sensing*, v. 8, n. 10, p. 1–19, 2016.

- LI, Z.; GUO, X. Remote sensing of terrestrial non-photosynthetic vegetation using hyperspectral, multispectral, SAR, and LiDAR data. **Progress in Physical Geography**, v. 40, n. 2, p. 276–304, 2016.
- LICHTENTHALER, H. K. Chlorophylls and Carotenoids: Pigments of Photosynthetic Biomembranes. **Methods in Enzymology**, v. 148, n. C, p. 350–382, 1987.
- LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote Sensing and Image Interpretation**. 7. ed. Washington: Wiley, 2015.
- LONGLEY, P. A. et al. **Sistemas e Ciência da Informação Geográfica**. 3. ed. Porto Alegre, RS: Bookman Editora, 2013.
- LORENZZETTI, J. A. **Princípios Físicos de Sensoriamento Remoto**. 1. ed. São Paulo, SP: Editora Edgard Blucher Ltda, 2015.
- LU, D. et al. Application of spectral mixture analysis to Amazonian land-use and land-cover classification. **International Journal of Remote Sensing**, v. 25, n. 23, p. 5345–5358, 2004.
- LUO, J. et al. Management options to reduce nitrous oxide emissions from intensively grazed pastures: A review. **Agriculture, Ecosystems and Environment**, v. 136, n. 3–4, p. 282–291, 2010.
- MACEDO, M. C. M. Integração lavoura e pecuária: O estado da arte e inovações tecnológicas. **Revista Brasileira de Zootecnia**, v. 38, n. SUPPL. 1, p. 133–146, 2009.
- MACEDO, M. C. M. ; ZIMMER, A. H. **Sistemas pasto-lavoura e seus efeitos na produtividade agropecuária**. In: Favoretto, V.; Rodrigues, L. R. A.; Reis, R.A. (Ed.). **Simpósio sobre Ecossistemas das Pastagens, 2, 1993, Jaboticabal. Anais. Jaboticabal: FUNEP : UNESP, 1993. p. 216-245**. In: Favoretto, V.; Rodrigues, L. R. A.; Reis, R.A. (Ed.). **Simpósio sobre Ecossistemas das Pastagens, 2, 1993, Jaboticabal. Anais. Jaboticabal: FUNEP : UNESP, 1993. p. 216-245.**, 1993.
- MAIA, S. M. F. et al. Effect of grassland management on soil carbon sequestration in Rondônia and Mato Grosso states, Brazil. **Geoderma**, v. 149, n. 1–2, p. 84–91, 2009.
- MALHI, Y. et al. Climate change, deforestation, and the fate of the Amazon. **Science**, v. 319, n. 5860, p. 169–172, 2008.
- MAPA. Plano Setorial de Mitigação e Adaptação às Mudanças Climáticas para Consolidação da Economia de Baixa Emissão de Carbono na Agricultura – Plano ABC. 2012.
- MAPA. Plano setorial para adaptação à mudança do clima e baixa emissão de carbono na agropecuária com vistas ao desenvolvimento sustentável (2020-2030): visão estratégica para um novo ciclo. 2021a.
- MAPA. **Institucional** — **Português (Brasil)**. Disponível em:

<<https://www.gov.br/agricultura/pt-br/aceso-a-informacao/institucional>>. Acesso em: 5 out. 2021b.

MAPBIOMAS. **Projeto MapBiomias – Coleção 6 da Série Anual de Mapas de Uso e Cobertura da Terra do Brasil.** Disponível em:

<[https://plataforma.brasil.mapbiomas.org/?activeBaseMap=8&layersOpacity=70&activeModule=coverage&activeModuleContent=coverage%3Acoverage_main&activeYear=2020&mapPosition=-15.072124%2C-](https://plataforma.brasil.mapbiomas.org/?activeBaseMap=8&layersOpacity=70&activeModule=coverage&activeModuleContent=coverage%3Acoverage_main&activeYear=2020&mapPosition=-15.072124%2C-51.547852%2C4&timelineLimitsRange=1985%2C2020&baseParams[territoryType]=>)

[51.547852%2C4&timelineLimitsRange=1985%2C2020&baseParams\[territoryType\]=>](https://plataforma.brasil.mapbiomas.org/?activeBaseMap=8&layersOpacity=70&activeModule=coverage&activeModuleContent=coverage%3Acoverage_main&activeYear=2020&mapPosition=-15.072124%2C-51.547852%2C4&timelineLimitsRange=1985%2C2020&baseParams[territoryType]=>).

Acesso em: 5 out. 2021.

MARCHI, C. E. et al. **Morte de pastos de braquiárias.** Campo grande, MS: Embrapa gado de corte, 2006.

MARSETT, R. C. et al. Remote sensing for grassland management in the arid Southwest. **Rangeland Ecology and Management**, v. 59, n. 5, p. 530–540, 2006.

MATHER, P. M.; KOCH, M. **Computer Processing of Remotely-Sensed Images: An Introduction.** 4. ed. Oxford: Wiley, 2011.

MATOS, J. **Fundamentos de informação geográfica.** 5. ed. Lisboa: LIDEL, 2008.

MAYES, M. et al. Going beyond the green: Senesced vegetation material predicts basal area and biomass in remote sensing of tree cover conditions in an African tropical dry forest (miombo woodland) landscape. **Environmental Research Letters**, v. 12, n. 8, 2017.

MAYES, M. T.; MUSTARD, J. F.; MELILLO, J. M. Forest cover change in Miombo Woodlands: Modeling land cover of African dry tropical forests with linear spectral mixture analysis. **Remote Sensing of Environment**, v. 165, p. 203–215, 2015.

MENESES, P. R.; ALMEIDA, T. DE. **Introdução ao processamento de imagem de sensoriamento remoto.** 1. ed. Brasília, DF: UnB, 2012.

MENEZES, P. M. L. DE; FERNANDES, M. DO C. **Roteiro de cartografia.** 1. ed. São Paulo, SP: Oficina de Textos, 2013.

MERZLYAK, M. N.; GITELSON, A. Why and What for the Leaves Are Yellow in Autumn? On the Interpretation of Optical Spectra of Senescing Leaves (Acer platanoides L.) 1. **Journal of Plant Physiology**, v. 145, n. 3, p. 315–320, 1995.

MEYER, T.; OKIN, G. S. Evaluation of spectral unmixing techniques using MODIS in a structurally complex savanna environment for retrieval of green vegetation, nonphotosynthetic vegetation, and soil fractional cover. **Remote Sensing of Environment**, v. 161, p. 122–130, 2015.

MMA. **Portal de informações ambientais ODS/MMA – Objetivo 2.** Disponível em:

<<http://www.mma.gov.br/informma/item/11530-objetivo-2-fome-zero-e-agricultura-sustentavel>>.

MMA. **Mata Atlântica**. Disponível em: <https://antigo.mma.gov.br/biomas/mata-atlantica_emdesenvolvimento.html>. Acesso em: 20 jun. 2022.

MUELLER-WILM, U.; DEVIGNOT, O.; PESSIOT, L. **Sen2Cor Configuration and User Manual**. esa, **Sentinel 2**, 2016.

NAGLER, P. L.; DAUGHTRY, C. S. T.; GOWARD, S. N. Plant litter and soil reflectance. **Remote Sensing of Environment**, v. 71, n. 2, p. 207–215, 2000.

NETO, J. F. T. T. et al. **Prováveis causas da morte do capim-braquiarião (Brachiaria brizantha cv. Marandu) na Amazônia Oriental: relatório técnico**. Belém: [s.n.].

NOVO, E. M. L. M. **Sensoriamento Remoto: Princípios e Aplicações**. 4. ed. São Paulo, SP: [s.n.].

NUMATA, I. et al. Characterization of pasture biophysical properties and the impact of grazing intensity using remotely sensed data. **Remote Sensing of Environment**, v. 109, n. 3, p. 314–327, 2007.

NUMATA, I. et al. Evaluation of hyperspectral data for pasture estimate in the Brazilian Amazon using field and imaging spectrometers. **Remote Sensing of Environment**, v. 112, n. 4, p. 1569–1583, 2008.

OKIN, G. S. et al. Practical limits on hyperspectral vegetation discrimination in arid and semiarid environments. **Remote Sensing of Environment**, v. 77, n. 2, p. 212–225, 2001.

PAESE, A. et al. **Conservação da biodiversidade com SIG**. 1. ed. São Paulo, SP: Oficina de Textos, 2015.

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

PARENTE, L.; FERREIRA, L. Assessing the spatial and occupation dynamics of the Brazilian pasturelands based on the automated classification of MODIS images from 2000 to 2016. **Remote Sensing**, v. 10, n. 4, 2018.

PEÑA-BARRAGÁN, J. M. et al. Object-based crop identification using multiple vegetation indices, textural features and crop phenology. **Remote Sensing of Environment**, v. 115, n. 6, p. 1301–1316, 2011.

PEREIRA, O. J. R. et al. Assessing pasture degradation in the Brazilian Cerrado based on the analysis of MODIS NDVI time-series. **Remote Sensing**, v. 10, n. 11, 2018.

PIRATELLI, A. J.; FRANCISCO, M. R. **Conservação da biodiversidade: dos conceitos às ações**. 1. ed. Rio de Janeiro: Technical Books Editora, 2013.

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

PRIMAVESI, O. et al. **Manejo alimentar de bovinos leiteiros e sua relação com produção de metano ruminal**. [s.l.: s.n.]. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/37258/1/Circular39.pdf>>. Acesso em: 4 nov. 2021.

PRIMAVESI, O.; ARZABE, C.; DOS SANTOS PEREIRA, M. **Aquecimento global e mudanças climáticas: uma visão integrada tropical**. [s.l.] Embrapa Pecuária Sudeste, 2007.

QI, J. et al. A modified soil adjusted vegetation index. **Remote Sensing of Environment**, v. 48, n. 2, p. 119–126, 1994.

QI, J. et al. **RANGES improves satellite-based information and land cover assessments in Southwest United States**. *Eos*, 2002.

RBMA. **A Mata Atlântica**. Disponível em: <<https://rbma.org.br/n/a-mata-atlantica/>>. Acesso em: 20 jun. 2022.

REDEILPF. **ILPF em números: Safra 2020/21**. [s.l.: s.n.]. Disponível em: <https://www.redeilpf.org.br/images/ILPF_em_Numeros-Safra.pdf>.

REINERMANN, S.; ASAM, S.; KUENZER, C. Remote Sensing of Grassland Production and Management—A Review. **Remote Sensing**, v. 12, n. 12, p. 1949, 17 jun. 2020.

REN, H. R. et al. Evaluating cellulose absorption index (CAI) for non-photosynthetic biomass estimation in the desert steppe of Inner Mongolia. **Chinese Science Bulletin**, v. 57, n. 14, p. 1716–1722, 2012.

REN, H.; ZHOU, G. Estimating green biomass ratio with remote sensing in arid grasslands. **Ecological Indicators**, v. 98, n. 79, p. 568–574, 2019.

ROBERTS, D. A. et al. Evaluation of the potential of Hyperion for fire danger assessment by comparison to the airborne visible/infrared imaging spectrometer. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 6 PART I, p. 1297–1310, 2003.

ROBERTS, D. A.; SMITH, M. O.; ADAMS, J. B. Green vegetation, nonphotosynthetic vegetation, and soils in AVIRIS data. **Remote Sensing of Environment**, v. 44, n. 2–3, p. 255–269, 1993.

RODRIGUEZ-GALIANO, V. F. et al. Random Forest classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture. **Remote Sensing of Environment**, v. 121, p. 93–107, 2012a.

RODRIGUEZ-GALIANO, V. F. et al. An assessment of the effectiveness of a random forest classifier for land-cover classification. **ISPRS Journal of Photogrammetry and Remote**

Sensing, v. 67, n. 1, p. 93–104, 2012b.

ROTH, K. L.; DENNISON, P. E.; ROBERTS, D. A. Comparing endmember selection techniques for accurate mapping of plant species and land cover using imaging spectrometer data. **Remote Sensing of Environment**, v. 127, p. 139–152, 2012.

ROUSE, J. W. et al. Monitoring vegetation systems in the Great Plains with ERTS. **Nasa ERTS Symposium**, p. 309–313, 1973.

RURAL SUSTENTÁVEL. **iLPF: integração Lavoura-Pecuária-Floresta**. Disponível em: <http://mata-atlantica-amazonia.ruralsustentavel.org/wp-content/uploads/2021/01/Infografico_iLPF.pdf>. Acesso em: 20 maio. 2022.

RURAL SUSTENTÁVEL CERRADO. **Sobre o projeto – Rural Sustentável**. Disponível em: <<https://www.ruralsustentavel.org/projeto/sobre-o-projeto/>>. Acesso em: 14 maio. 2022.

SAUSEN, T. M.; LACRUZ, M. S. P. **Sensoriamento remoto para desastres**. 1. ed. São Paulo, SP: Oficina de Textos, 2015.

SERRÃO, E. A.; UHL, C.; NEPSTAD, D. C. **Deforestation for pasture in the humid tropics: Is it economically and environmentally sound in the long term?** [s.l.] Proceedings of the XVII International Grassland Congress, 1993.

SHI, T.; XU, H. Derivation of Tasseled Cap Transformation Coefficients for Sentinel-2 MSI At-Sensor Reflectance Data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 12, n. 10, p. 4038–4048, 2019.

SHIMABUKURO, Y. E.; PONZONI, F. J. **Mistura espectral: modelo linear e aplicações**. 1. ed. São Paulo, SP: Oficina de Textos, 2017.

SIMS, D. A.; GAMON, J. A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. **Remote Sensing of Environment**, v. 81, n. 2–3, p. 337–354, 2002.

SOUSSANA, J. F.; TALLEC, T.; BLANFORT, V. Mitigating the greenhouse gas balance of ruminant production systems through carbon sequestration in grasslands. **Animal**, v. 4, n. 3, p. 334–350, 2010.

STONER, E. R.; BAUMGARDNER, M. F. Characteristic variations in reflectance of surface soils. **Soil Science Society of America Journal**, v. 45, n. 6, p. 1161–1165, 1981.

UN. Transforming our world: the 2030 agenda for sustainable development. 2015.

USGS. **USGS EROS Archive - Earth Observing One (EO-1) - Hyperion | U.S. Geological Survey**. Disponível em: <<https://www.usgs.gov/centers/eros/science/usgs-eros-archive-earth-observing-one-eo-1-hyperion>>. Acesso em: 18 jun. 2022.

VALENTIM, J. F.; AMARAL, E. F.; MELO, A. W. F. **Zoneamento de risco edáfico atual e**

potencial de morte de pastagens Brachiaria brizantha no Acre. Rio Branco: [s.n.].

VALLE JÚNIOR, R. F. DO et al. Diagnosis of degraded pastures using an improved NDVI-based remote sensing approach: An application to the Environmental Protection Area of Uberaba River Basin (Minas Gerais, Brazil). **Remote Sensing Applications: Society and Environment**, v. 14, n. November 2018, p. 20–33, 2019.

VAN DEVENTER, A. P. et al. Using thematic mapper data to identify contrasting soil plains and tillage practices. **Photogrammetric Engineering and Remote Sensing**, v. 63, n. 1, p. 87–93, 1997.

VEIGA, J. B. et al. **Sistemas silvipastoris na Amazônia oriental.** Belém: [s.n.].

VIÑA, A. et al. Comparison of different vegetation indices for the remote assessment of green leaf area index of crops. **Remote Sensing of Environment**, v. 115, n. 12, p. 3468–3478, 2011.

WANG, L.; QU, J. J. NMDI: A normalized multi-band drought index for monitoring soil and vegetation moisture with satellite remote sensing. **Geophysical Research Letters**, v. 34, n. 20, p. 1–5, 2007.

WARDLOW, B. D.; EGBERT, S. L.; KASTENS, J. H. Analysis of Time-Series MODIS 250 m Vegetation Index Data for Crop Analysis of time-series MODIS 250 m vegetation index data for crop classification in the U . S . Central Great Plains. n. June, 2007.

WERNER, J. C. **Adubação de pastagens.** Nova Odessa: [s.n.].

WONG, K. K.; HE, Y. Estimating grassland chlorophyll content using remote sensing data at leaf, canopy, and landscape scales. **Canadian Journal of Remote Sensing**, v. 39, n. 2, p. 155–166, 2013.

WOOD, E. M. et al. Image texture as a remotely sensed measure of vegetation structure. **Remote Sensing of Environment**, v. 121, p. 516–526, 2012.

YOUNG, A. J.; LOWE, G. L. Carotenoids—antioxidant properties. **Antioxidants**, v. 7, n. 2, p. 10–13, 2018.

YUE, Y. et al. Spectral indices for estimating ecological indicators of karst rocky desertification. **International Journal of Remote Sensing**, v. 31, n. 8, p. 2115–2122, 2010.

ZANOTTA, D. C.; FERREIRA, M. P.; ZORTEA, M. **Processamento de imagens de satélite.** 1. ed. São Paulo, SP: Oficina de Textos, 2019.

ZIMMER, A. H. et al. **Degradação, recuperação e renovação de pastagens.** Brasília: [s.n.].