



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



sid.inpe.br/mtc-m21d/2021/12.10.17.35-TDI

AVALIAÇÃO DO USO DE DADOS ÓPTICOS E DE MICRO-ONDAS NO MONITORAMENTO DE PASTAGENS NA AMAZÔNIA BRASILEIRA

Arian Ferreira Carneiro

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelo Dr. Sidnei João Siqueira
Sant'Anna, aprovada em 13 de
dezembro de 2021.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/45UD35E>>

INPE
São José dos Campos
2021

PUBLICADO POR:

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

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

Presidente:

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

Membros:

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

BIBLIOTECA DIGITAL:

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

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

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

EDITORAÇÃO ELETRÔNICA:

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



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



sid.inpe.br/mtc-m21d/2021/12.10.17.35-TDI

AVALIAÇÃO DO USO DE DADOS ÓPTICOS E DE MICRO-ONDAS NO MONITORAMENTO DE PASTAGENS NA AMAZÔNIA BRASILEIRA

Arian Ferreira Carneiro

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelo Dr. Sidnei João Siqueira
Sant'Anna, aprovada em 13 de
dezembro de 2021.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/45UD35E>>

INPE
São José dos Campos
2021

Dados Internacionais de Catalogação na Publicação (CIP)

Carneiro, Arian Ferreira.

C215a Avaliação do uso de dados ópticos e de micro-ondas no monitoramento de pastagens na Amazônia Brasileira / Arian Ferreira Carneiro. – São José dos Campos : INPE, 2021.
xxii + 131 p. ; (sid.inpe.br/mtc-m21d/2021/12.10.17.35-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2021.
Orientador : Dr. Sidnei João Siqueira Sant’Anna.

1. Séries temporais. 2. Pastagem. 3. Bioma Amazônia. 4. Radar de abertura sintética. I.Título.

CDU 528.8:633.2.033(811)



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

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

MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS
Serviço de Pós-Graduação - SEPGR

DEFESA FINAL DE DISSERTAÇÃO DE ARIAN FERREIRA CARNEIRO
BANCA Nº 315/2021, REG 225202/19

No dia 13 de dezembro de 2021, às 14h00min, por teleconferência, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestre em Sensoriamento Remoto. O trabalho precisa da incorporação das correções sugeridas pela Banca e revisão final pelo(s) orientador (es).

Título: "AVALIAÇÃO DO USO DE DADOS ÓPTICOS E DE MICRO-ONDAS NO MONITORAMENTO DE PASTAGENS NA AMAZÔNIA BRASILEIRA"

Membros da Banca:

Dr. Thales Sehn Korting - Presidente - INPE
Dr. Sidnei João Siqueira Sant'Anna - Orientador - INPE
Dr. Marcos Adami - Membro Interno - INPE
Dr. Cláudio Aparecido Almeida - Membro Interno - INPE
Dr. Amaury Burlamaqui Bendahan - Membro Externo - EMBRAPA



Documento assinado eletronicamente por **Claudio Aparecido de Almeida, Chefe da Divisão de Projeto Estratégico 1**, em 14/12/2021, às 07:59 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Thales Sehn Korting, Pesquisador**, em 14/12/2021, às 08:32 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Amaury burlamaqui bendahan (E), Usuário Externo**, em 14/12/2021, às 08:39 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Sidnei João Siqueira SantAnna, Tecnologista**, em 14/12/2021, às 08:57 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Marcos Adami, Pesquisador**, em 27/12/2021, às 09:10 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <http://sei.mctic.gov.br/verifica.html>, informando o código verificador **8760927** e o código CRC **7BCBEFA7**.

Referência: Processo nº 01340.008656/2021-15

SEI nº 8760927

“Tudo depende do tipo de lente que você usa para ver as coisas”.

JUSTEIN GAARDER
em “O Mundo de Sofia”, 1991

*A **Deus**, por conceder mais esta conquista. Minha família, companheira e amigos pelas experiências vividas até aqui.*

AGRADECIMENTOS

Aos meus pais, Alexandre e Denise, pelo amor e dedicação à minha criação e educação bem como a de meu irmão André. À minha amada Felícia, pelo companheirismo e apoio durante toda esta etapa.

Aos docentes e discentes do curso de pós-graduação em Sensoriamento Remoto do INPE que contribuíram com minha formação acadêmica e pessoal ao longo desta trajetória. Em especial ao meu orientador Dr. Sidnei Sant'Anna pela oportunidade, toda a paciência, amizade e conselhos durante o meu período de formação acadêmica.

Aos Drs. Cláudio Almeida e Amaury Bendahan pela viabilização e contribuições valiosas obtidas durante o período do mestrado, sobretudo na campanha de campo em Roraima, uma experiência única.

Aos amigos da SER-2019, pelas noites de estudo, momentos de descontração e viagens. Em especial ao amigo Juan Doblaz, pelas valiosas discussões ao longo desta pesquisa.

À CAPES pela concessão da bolsa de estudos e ao Instituto Nacional de Pesquisas Espaciais por meio do curso de pós-graduação em Sensoriamento Remoto pelo fomento à pesquisa e a oportunidade desta formação acadêmica.

Aos meus amigos de Belém: Ewerton, Phelipe e Marcelo que estão sempre presentes para uma boa conversa e lazer, altamente necessário durante o período de pesquisa somados à pandemia.

Meu muito obrigado aos amigos Willian, Daiane, Caio, Rogério e Daniel e um agradecimento especial, aos amigos com quem dividi moradia na república Cab. da Leila: Fábio, Denis, Ana e Felipe Sá, vocês tornaram essa caminhada muito mais amena e alegre.

RESUMO

A atividade pecuária ocorre em cerca de 47% dos estabelecimentos agropecuários do Brasil. O crescimento desordenado de pastagens oferece riscos ambientais sobretudo a áreas de floresta, alterando o equilíbrio natural existente, com impactos diretos na dinâmica climática da região. Ocorrendo em 60% de áreas desflorestadas na Amazônia Legal, as pastagens constituem a maior classe de uso e cobertura da terra, ocupando cerca de 21,28% da área do País em 2018. No bioma Amazônia, uma área de aproximadamente 46,2 milhões de hectares é ocupada por pastagens. Frente a extensão territorial e as dificuldades logísticas de fiscalização ambiental, o sensoriamento remoto atua como ferramenta primordial no monitoramento das pastagens no que tange a detecção e qualificação destas áreas de forma sistemática. Contudo, para regiões de clima tropical úmido, o monitoramento via sensoriamento remoto óptico é condicionado pela alta ocorrência de nuvens, condicionante esta que pouco influencia os sensores imageadores que operam no espectro das micro-ondas. Deste modo, o objetivo desta pesquisa visa a investigação do potencial de dados derivados de séries temporais de imagens de sensoriamento remoto dos satélites Sentinel-1 (SAR - banda C) e Sentinel-2 (MSI - *Multispectral Scanner Instrument*) para o mapeamento, discriminação e indicativos de qualidade das pastagens na região sul do estado de Roraima, visando subsidiar programas de monitoramento da Amazônia. Para tanto, foram utilizadas séries temporais, relativas a dois anos, de dados ópticos e de micro-ondas. A investigação foi baseada em produtos de classificação digital de imagens, cujo processo foi dividido em 3 principais etapas. Primeiramente discriminou-se a classe Pastagem de outras classes de uso e cobertura da terra. Em seguida diferenciou-se a Pastagem em Arbustiva e Herbácea e finalmente estas 2 últimas classes foram qualificadas segundo seus indicativos de degradação. Nestas 3 etapas foram extraídos e selecionados atributos derivados de séries temporais de dados ópticos, de radar, bem como da combinação dos dados destes dois tipos de sensor. O algoritmo *Random Forest* foi empregado na classificação dos dados e o experimento Monte Carlo foi utilizado para apoio na validação dos resultados. Dentre os resultados obtidos, para a Etapa 1, o conjunto formado pela combinação das métricas extraídas das séries ópticas e de radar obteve a melhor performance, com acurácia global de 94,05%. Os resultados da adição dos dados de radar na classificação evidenciaram ganho significativo na diminuição da confusão de áreas de pastos com a presença de solo exposto com áreas urbanas. Para a Etapa 2, o resultado da classificação dos conjuntos de dados combinado (óptico e SAR) e apenas óptico obtiveram a melhor performance, pois não apresentaram diferença significativa ($\alpha = 10\%$) entre eles, o que garante melhor cenário para o classificação do conjunto de dados óptico (acurácia global de 87,88%), uma vez que há menor complexidade no processamento de uma única fonte. Na Etapa 3, o NDVI foi utilizado como intermediário com relação à qualidade das pastagens. A determinação dos indicativos de degradação foi feita com base no fatiamento do $NDVI_m$ para quatro classes (Ausente, Leve, Moderada e Severa), onde foi possível obter 64% de acurácia global. Quando consideradas apenas duas classes (Ausente e Degradado), foi possível

observar um aumento da acurácia global para 72%. Utilizando dados SAR, uma regressão linear múltipla foi aplicada para obtenção de uma relação com a degradação de pastagens, considerando o NDVI como referência ($r^2 = 0,6$). Os resultados obtidos na determinação obtiveram acurácias de 43% e 68% quando consideradas 4 classes (Ausente, Leve, Moderada e Severa) e quando generalizadas apenas a 2 classes (Ausente e Degradado), respectivamente. Por fim, com base na combinação dos melhores cenários obtidos para cada uma das etapas, foi possível a obtenção de um resultado final para a área de estudo com informações detalhadas das pastagens na região.

Palavras-chave: Séries temporais. Pastagem. Bioma Amazônia. Radar de Abertura Sintética.

EVALUATION OF THE USE OF OPTICAL AND MICROWAVE DATA IN THE MONITORING OF PASTURES IN THE BRAZILIAN AMAZON

ABSTRACT

Livestock activity occurs in about 47% of agricultural establishments in Brazil. The disorderly growth of pastures poses environmental risks, above all to forest areas, altering the existing natural balance, with direct impacts on the region's climate dynamics. Occurring in 60% of deforested areas in the Legal Amazon, pastures constitute the largest land use and cover class, occupying about 21.28% of the country's area at 2018. In the Amazon biome, an area of approximately 46.2 million hectares is occupied by pastures. Given the territorial extension and the logistical difficulties of environmental inspection, remote sensing acts as an essential tool in monitoring pastures concerning the detection and qualification of these areas in a systematic way. However, for regions with a humid tropical climate, monitoring via optical remote sensing is conditioned to the high occurrence of clouds, a condition that has less influence on microwave imaging sensors. Thus, this research aims to investigate the potential of data derived from time series of remote sensing images from Sentinel-1 (SAR - C-band) and Sentinel-2 (MSI - Multispectral Scanner Instrument) satellites for mapping, discrimination, and quality indicators of pastures in the southern region of the state of Roraima, aiming to support monitoring programs in the Amazon. For this purpose, two-year time series of optical and microwave data were used. The investigation was based on digital image classification products, whose process was divided into 3 main steps. Firstly, the Pasture class was distinguished from other classes of land use and land cover. Then, the Shrub and Herbaceous pastures were distinguished and finally, these 2 last classes were classified according to their indications of degradation. In these 3 steps, attributes derived from time series of optical and radar data were extracted and selected, as well as the combination of data from these two types of sensors. The Random Forest algorithm was used to classify the data and the Monte Carlo experiment was used to support the validation of the results. Among the results obtained, for Step 1, the set formed by the combination of metrics extracted from both the optical and radar series obtained the best performance, with an overall accuracy of 94.05%. The results of adding radar data to the classification showed a significant gain in reducing the confusion of pasture areas with the presence of exposed soil with urban areas (since the presence of areas without asphalt pavement is common in this area). For Step 2, the result of the classification of the combined and optical sets obtained the best performance, with no significant difference ($\alpha = 10\%$) between them, which guarantees the best scenario for the optical (global accuracy of 87,88%), since there is less complexity in processing a single source. In Step 3, the NDVI was used as an intermediary about pasture quality. The determination of degradation indicators based on the NDVI obtained accuracies of 64% and 72%, when considering 4 classes (Absent, Mild, Moderate, and Severe) and when generalized only to 2 classes (Absent and Degraded), respectively. Using SAR data, a multiple linear regression was applied to obtain a relationship with pasture degradation, considering the NDVI ($r^2 = 0.6$). The results obtained in the determination obtained accuracies of 43% and 68% when

considering 4 classes (Absent, Mild, Moderate, and Severe) and when generalized only to 2 classes (Absent and Degraded), respectively. Finally, based on the combination of the best scenarios obtained for each of the stages, it was possible to obtain a final result for the study area with detailed information on pastures in the region.

Keywords: Time series. Pasture. Amazon Biome. Synthetic Aperture Radar.

LISTA DE FIGURAS

	<u>Pág.</u>
1.1 Observações livres de nuvens e sombras para o satélite Landsat-8, nas imagens utilizadas pelo MapBiomias em 2019, para o Bioma Amazônia.	3
2.1 Distribuição espacial das pastagens pelo bioma Amazônia, para o ano de 2018.	7
2.2 Número de publicações por ano, utilizando as palavras-chave <i>Remote Sensing</i> , <i>Time series</i> e <i>Pasturelands</i> no repositório da <i>Science Direct</i>	10
2.3 Associação de valores de uma série temporal a determinado ângulo (esquerda), geometria fechada formada a partir da transformação dos valores para um plano polar (direita).	21
3.1 Área de estudo.	25
3.2 Proximidade da área de estudo em relação a unidades de conservação e reservas indígenas.	26
3.3 Pontos de GNSS das pastagens visitadas em campo.	30
3.4 Chave de interpretação para as classes de pastagem Herbácea e Arbustiva.	31
3.5 Distribuição espacial dos pontos de campo juntamente com pontos gerados com base na chave de interpretação.	32
3.6 Mapas de uso e cobertura do solo utilizados para a área de estudo: A) TerraClass 2014; B) MapBiomias 2019 e C) Combinação dos mapeamentos.	35
3.7 Fluxograma de procedimentos.	37
3.8 Procedimentos para obtenção de indicativos de degradação de pastagens baseado em séries temporais de NDVI.	47
3.9 Chave de interpretação para atribuição de indicativos de degradação de pastagens para as amostras utilizadas na validação dos métodos utilizados.	48
4.1 Valores do índice \mathcal{M} representado nas componentes estrutural e de suavização.	51
4.2 Imagem original e imagens filtradas associadas à imagem razão. A seta vermelha destaca as feições remanescentes na imagem razão.	53
4.3 Gráficos de dispersão e de série temporal dos canais SAR, para as classes de interesse (Etapa 1).	55
4.4 Valor p do teste KS relativo ao ajuste das amostras pertinentes à Etapa 1 a uma distribuição Gama nos canais do conjunto de dados SAR.	57

4.5	Composição colorida com os três atributos SAR que obtiveram maior JM para a Etapa 1.	59
4.6	Gráficos de dispersão e de série temporal dos canais SAR, para as classes de interesse (Etapa 2).	60
4.7	Desvio do valor do retorno do sinal dos canais SAR com relação à média do valor de todo o período analisado, para as classes Pastagem Arbustiva e Herbácea associadas a dados de precipitação. As linhas tracejadas verticais cinza e vermelho sinalizam, respectivamente, observações do início e final do período chuvoso (20 de abril de 2019 à 01 de novembro de 2019).	62
4.8	Valor p do teste KS relativo ao ajuste das amostras pertinentes à Etapa 2 a uma distribuição Gama nos canais do conjunto de dados SAR.	64
4.9	Composição colorida com os três atributos SAR que obtiveram maior JM para a Etapa 2.	66
4.10	Gráficos de dispersão e de série temporal dos canais ópticos, para as classes de interesse (Etapa 1).	67
4.11	Composição colorida com os três atributos ópticos que obtiveram maior JM média para a Etapa 1.	70
4.12	Gráficos de dispersão e de série temporal dos canais ópticos, para as classes de interesse (Etapa 2).	71
4.13	Consequência da ocorrência frequente de nuvens na construção de séries temporais com dados ópticos.	73
4.14	Desvio da média diária do retorno do sinal dos canais ópticos com relação à média de todo o período analisado, associado à dados de precipitação para as classes Pastagem Herbácea e Arbustiva.	75
4.15	Composição colorida com os três atributos ópticos que obtiveram maior JM média para a Etapa 2.	76
4.16	Composição colorida com os três atributos do conjunto de dados combinado que obtiveram maior JM média para a Etapa 1.	78
4.17	Composição colorida com os três atributos do conjunto de dados combinado que obtiveram maior JM média para a Etapa 1.	79
4.18	Resultado da classificação de uso e cobertura da terra utilizando atributos SAR (Etapa 1).	81
4.19	Elementos passíveis de confusão presentes na classificação de dados de radar.	82
4.20	Resultado da classificação de uso e cobertura da terra utilizando atributos ópticos (Etapa 1).	84
4.21	Exemplos de confusões na classificação de dados ópticos: A) Pastagem e Área Urbanizada e; B) Pastagem e Corpos D'Água (erros de comissão).	85

4.22	Número de observações livres de nuvens por pixel para a composição das métricas temporais utilizadas no processo de classificação do conjunto de dados ópticos. Salienta-se que foram utilizados um conjunto de 145 imagens no estudo.	86
4.23	Resultado da classificação de uso e cobertura da terra utilizando atributos SAR e óptico combinados (Etapa 1).	87
4.24	Exemplos da confusão na classificação usando atributos combinados: (A) Pastagem e Área Urbanizada e (B) Pastagem e Corpos D'Água.	88
4.25	Imagens de concordância entre as classificações para a Etapa 1.	90
4.26	Classificação dos tipos de pastagem usando atributos SAR (Etapa 2).	94
4.27	Exemplos de áreas classificadas como Pastagem Arbustiva, destacados pelas setas brancas, com base nos atributos de radar.	95
4.28	Classificação dos tipos de pastagem usando atributos ópticos (Etapa 2).	96
4.29	Exemplos de áreas classificadas como Pastagem Arbustiva, destacados pelas setas brancas, com base nos atributos ópticos.	97
4.30	Classificação dos tipos de pastagem usando atributos SAR e ópticos (Etapa 2).	98
4.31	Recorte dos resultados de classificação para os conjuntos: (A) SAR, (B) Óptico e (C) Combinado. Adicionalmente estão dispostas as composições coloridas representativas para a Etapa 2 de cada conjunto de dados.	99
4.32	Imagens resultado da diferença entre as classificações para a Etapa 2.	100
4.33	Indicativos de degradação para as Pastagens, obtidos pelo fatiamento do $NDVI_m$ normalizado.	104
4.34	Indicativos de qualidade de pastagens do Mapbiomas para a região, para o ano de 2018.	105
4.35	Comparação dos indicativos de degradação obtidos pelo fatiamento do $NDVI_m$ gerado na pesquisa e dos dados disponibilizados pelo Mapbiomas.	106
4.36	Indicativos de degradação para as pastagens, obtidos pelo fatiamento do $NDVI_{SAR}$	108
4.37	Resultado dos indicativos de degradação considerando apenas 2 classes, para o conjunto de dados: (a) óptico e (b) SAR.	110
4.38	Imagem de concordância entre os indicativos de degradação gerados pelos conjuntos de dados SAR e óptico.	112
4.39	Distribuição espacial das classes Pastagem Herbácea e Arbustiva, associadas à 4 níveis de degradação.	114

LISTA DE TABELAS

	<u>Pág.</u>
3.1 Bandas espectrais do Sentinel-2A (S2A) e Sentinel-2B (S2B).	28
3.2 Características das imagens utilizadas para a construção das séries temporais.	29
3.3 Correspondência de classes predominantes presentes nos mapeamentos de uso e cobertura do solo para a área de estudo.	33
3.4 Métricas utilizadas no processo de classificação.	41
3.5 Parâmetros de entrada para a execução do algoritmo <i>RandomizedSearchCV</i> . Em destaque, estão os parâmetros ótimos elencados pela técnica.	44
3.6 Exemplo de matriz de contingência.	45
4.1 Parâmetros testados para os diferentes filtros de <i>speckle</i>	50
4.2 Valores do índice \mathcal{M} e suas componentes para os filtros destacados. Valores em negrito representam os melhores resultados para cada componente.	52
4.3 Métricas SAR selecionadas para a Etapa 1, ordenadas segundo o valor de JM	58
4.4 Métricas SAR selecionadas para a Etapa 2, ordenadas segundo o valor de JM	65
4.5 Métricas ópticas selecionadas para a Etapa 1, ordenadas segundo o valor de JM	69
4.6 Métricas ópticas selecionadas para a Etapa 2, ordenadas segundo o valor de JM média.	76
4.7 Métricas do conjunto de dados combinado selecionadas para a Etapa 1, ordenadas segundo o valor de JM média.	77
4.8 Métricas do conjunto de dados combinado selecionadas para a Etapa 2, ordenadas segundo o valor de JM média.	79
4.9 Área (ha) das classes de uso e cobertura do solo para a área de estudo computadas sobre os diferentes resultados de classificação.	91
4.10 Resultado do teste de McNemar para as classificações para a Etapa 1, com um nível de significância de 10% ($\chi^2 > 2,706$).	92
4.11 Área (ha) relativas as classes de pastagens resultado da classificação para a Etapa 2.	101
4.12 Resultado do teste de McNemar para as classificações para a Etapa 2, com um nível de significância de 10% ($\chi^2 > 2,706$).	102
4.13 Área (ha) e proporção das classes de indicativos de degradação de pastagens presentes na área de estudo.	108

4.14	Área (ha) e proporção das classes de indicativos de degradação de pastagens presentes na área de estudo.	111
4.15	Área (ha) e proporção das classes de pastagem associadas aos indicativos de degradação presentes na área de estudo.	113

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Hipótese	5
2 FUNDAMENTAÇÃO TEÓRICA	7
2.1 Pastagens na Amazônia	7
2.2 Classificação de pastagens	9
2.3 Identificação e discriminação de pastagens com sensoriamento remoto	10
2.3.1 Sensoriamento remoto óptico	10
2.3.2 Sensoriamento remoto por micro-ondas	13
2.3.3 Abordagens com integração de dados	16
2.4 Técnicas de processamento digital de imagens	17
2.4.1 Filtragem do <i>speckle</i>	17
2.4.2 Técnicas de classificação	20
2.4.3 Síntese de séries temporais	21
3 MATERIAL E MÉTODOS	25
3.1 Caracterização da área de estudo	25
3.2 Dados	27
3.2.1 Sentinel-1	27
3.2.2 Sentinel-2	28
3.2.3 Trabalho de campo	29
3.2.4 Mapas de uso e cobertura do solo	33
3.3 Processamento dos dados	36
3.3.1 Filtragem de <i>speckle</i>	38
3.3.2 Máscara de nuvens	38
3.3.3 Geração de índices	38
3.3.4 Métricas temporais	40
3.3.5 Corregistro	42
3.3.6 Análise exploratória dos dados para a seleção de variáveis	42
3.4 Método de classificação e avaliação	43
3.4.1 <i>Random Forest</i>	43
3.4.2 Monte Carlo, indicativos de acurácia e imagens de concordância	44
3.4.3 Detecção da degradação	46

4	RESULTADOS E DISCUSSÕES	49
4.1	Avaliação de filtros de <i>speckle</i>	49
4.2	Análise exploratória e seleção de dados	54
4.2.1	Dados SAR	54
4.2.2	Dados ópticos	66
4.2.3	Combinação de dados	77
4.3	Resultados da classificação por <i>Random Forest</i>	80
4.3.1	Classificação de uso e cobertura da terra (Etapa 1)	81
4.3.1.1	Dados SAR	81
4.3.1.2	Dados ópticos	83
4.3.1.3	Dados combinados	87
4.3.2	Discriminação das diferentes pastagens (Etapa 2)	93
4.3.2.1	Dados SAR	93
4.3.2.2	Dados ópticos	95
4.3.2.3	Dados combinados	97
4.4	Indicativos de qualidade das pastagens - (Etapa 3)	103
4.4.1	Dados ópticos	103
4.4.2	Dados SAR	107
5	CONCLUSÕES E RECOMENDAÇÕES	115
	REFERÊNCIAS BIBLIOGRÁFICAS	121

1 INTRODUÇÃO

Dentre as principais atividades econômicas desenvolvidas no Brasil, dentro do que compete ao setor primário da economia, a atividade pecuária destaca-se como uma atividade econômica predominante em 47% dos estabelecimentos agropecuários do Brasil, sendo responsável por 34% do valor total da produção agropecuária brasileira (IBGE, 2019). Suas áreas, no Brasil, constituem a maior classe de uso e cobertura da terra, ocupando cerca de 18,73% da área do país em 2017, segundo dados do Instituto Brasileiro de Geografia e Estatística (IBGE), por meio do Censo Agropecuário para o ano de 2017 (IBGE, 2019).

Embora a pecuária contribua altamente para a economia do país, seu crescimento desordenado oferece riscos ambientais. Estudos de Barona et al. (2010) indicam que culturas agrícolas e pastagens são os padrões de uso e ocupação da terra mais recorrentes em áreas desflorestadas na Amazônia Brasileira, com destaque para as pastagens, que ocupam 60% destas áreas (ALMEIDA et al., 2016). Trabalhos de Veiga et al. (2004) e ZDWG (2017) também mostram que as pastagens vêm ocupando a maior parcela das áreas desmatadas da Amazônia.

As áreas referentes às pastagens naturais (i.e. áreas de campo utilizadas para o pastejo de animais) diminuíram, no Brasil, aproximadamente 18% em relação ao Censo Agropecuário de 2006 (57,6 milhões de hectares em 2006 para 47,3 milhões de hectares em 2017). Em contraponto, as áreas de pastagens plantadas que, neste caso incluem também as pastagens em más condições e aquelas em processo de recuperação na data de referência do Censo, aumentaram aproximadamente 10% com relação ao Censo Agropecuário de 2006 (102,4 milhões de hectares em 2006 para 112,1 milhões de hectares em 2017), o que também indica, por sua vez, um aumento nas pastagens com baixa eficiência (IBGE, 2019).

No ano de 2018, segundo o Atlas Digital das Pastagens Brasileiras, as pastagens ocuparam uma área relativa à 21,28% do território brasileiro. No bioma Amazônia, segundo o mesmo atlas, no ano de 2018 uma área de aproximadamente 46,2 milhões de hectares (11,01% do bioma) esteve ocupada por pastagens, com predominância, respectivamente, nos estados do Pará, Mato Grosso e Rondônia (UFG, 2021).

A conversão de florestas em pastagens, além de alterar o equilíbrio natural existente, causa impactos no ciclo de carbono e na dinâmica climática da região, dentre outros impactos ambientais. Impactos estes que se agravam com a utilização de fogo, prática comum na maioria das ocorrências de desmatamento na região. Tais indicadores,

associados a extensão e dificuldades logísticas de acesso as áreas de pastagem na Amazônia Legal, dificultam a fiscalização ambiental destas áreas *in loco*.

Uma alternativa para o monitoramento das pastagens frente a ótica do desmatamento é via sensoriamento remoto (SR). Cabe destacar também que, a resolução de nº 4427, de 25 de junho de 2015, do Banco Central autoriza a utilização do SR para fins de fiscalização de operações de crédito rural. Tais fatores reforçam a necessidade do desenvolvimento de metodologias de monitoramento das pastagens por SR.

No Brasil, alguns projetos mapeiam as pastagens via SR com destaque para o TerraClass e o MapBiomass. O TerraClass utiliza imagens de sensoriamento remoto, técnicas de interpretação e processamento de imagens de satélite para o mapeamento de uso e cobertura da terra no Brasil. Já o MapBiomass, utiliza de grandes volumes de dados associados a séries temporais e técnicas de aprendizado de máquina na classificação de imagens para a geração de imagens de uso e cobertura da terra.

No TerraClass é realizado o mapeamento de uso e cobertura da terra para os biomas Amazônia e Cerrado com frequência bienal (a partir de 2008). Atualmente, este projeto é desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE) e pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) com mapeamentos disponíveis para os anos de 2004, 2008, 2010, 2012 e 2014 para o bioma amazônia (ALMEIDA et al., 2016; EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA); INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE), 2020).

No MapBiomass é realizado o mapeamento de uso e cobertura da terra para todo o Brasil, com frequência anual, com dados disponíveis de 1985 a 2019. É desenvolvido por uma iniciativa multi institucional, envolvendo ONGs, universidades e empresas de tecnologia (MAPBIOMASS, 2020). Até a data desta pesquisa, ambos os projetos utilizam acervos de imagens Landsat (faixa óptica do espectro eletromagnético) como insumo para aplicação de técnicas de SR e interpretação dos respectivos resultados.

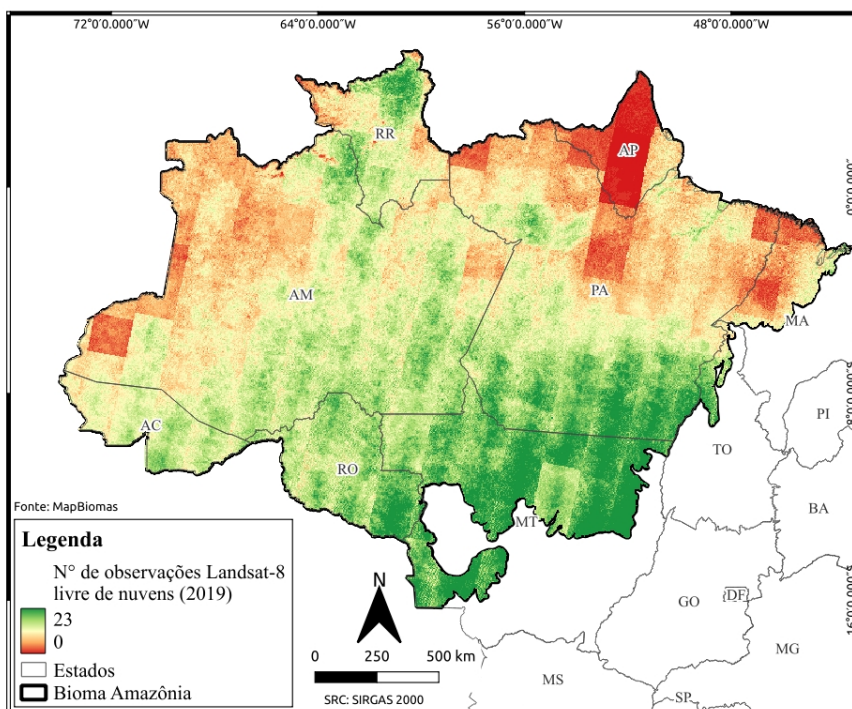
Em virtude das distintas definições de pasto, níveis de degradação e de diferentes técnicas de manejo presentes no território brasileiro, há uma dificuldade em se estabelecer um padrão para o processo de mapeamento de áreas de pastagem. Destaca-se também, como fator limitante, a baixa diferença espectral da pastagem com outras classes de uso e ocupação do solo como algumas culturas agrícolas e vegetação secundária, sobretudo na estação seca (PARENTE et al., 2019). Tais fatores podem ser atenuados com a utilização de séries temporais capazes de agregar informações sobre

estágios fenológicos, clima, manejo entre outras.

Ao se tratar de áreas que estão inseridas no bioma Amazônia, outra condicionante ao monitoramento contínuo das pastagens pela extensão do bioma é estabelecida. Devido ao clima tropical úmido da região (DIAS-FILHO; ANDRADE, 2006), são características deste clima a presença de um alto índice pluviométrico, acompanhado de grandes atividades convectivas ao longo do ano. Fatores estes que limitam a utilização de sensores ópticos.

Na Figura 1.1 é evidenciado, em paleta de cores do vermelho para o verde, o número de observações livres de nuvens por pixel considerando o sensor OLI do satélite Landsat-8 para o Bioma Amazônia, computado pelo MapBiomas para o ano de 2019. Observa-se que as áreas contidas num raio de dois graus da linha do equador (i.e., entre 2°S e 2°N) foram as mais afetadas pela concentração de nuvens, o que justifica o emprego de metodologias que incluem sensores que operam no espectro das micro-ondas.

Figura 1.1 - Observações livres de nuvens e sombras para o satélite Landsat-8, nas imagens utilizadas pelo MapBiomas em 2019, para o Bioma Amazônia.



Fonte: Adaptado de Mapbiomas (2020).

Os sensores imageadores que operam no espectro de micro-ondas por sua vez, em virtude do intervalo de comprimento de onda no qual operam e por serem, na sua maioria, sensores ativos (i.e., independem de fontes externas de radiação eletromagnética – REM), são menos influenciados pelas condicionantes atmosféricas comparados aos sensores que operam no espectro óptico. A utilização destes destes sensores viabiliza, teoricamente, um monitoramento constante da superfície terrestre.

Pesquisas que utilizam dados de sensores de micro-ondas (radares), mostram grande potencial na discriminação de pastagens (WANG et al., 2013; BARRETT et al., 2014; ABDIKAN et al., 2016; DINIZ, 2019; DINIZ; GAMA, 2019; TARAVAT et al., 2019), utilizando técnicas de classificação não-paramétricas como *Support Vector Machine* (SVM), *Random Forest* (RF) e Redes Neurais Artificiais. Devido a essa habilidade de operar sob condições atmosféricas adversas para os sensores ópticos e em altas resoluções espaciais, além da sua faixa de frequência possuir determinada sensibilidade à biomassa e à umidade, os radares de abertura sintética podem complementar, perfeitamente, os sensores ópticos no monitoramento das pastagens (WANG et al., 2013; BARRETT et al., 2014).

Abordagens utilizando ambos os sensores – ópticos e de radar – vem sendo trabalhadas pela comunidade científica no escopo de mapeamentos operacionais voltados para a discriminação de classes de uso e cobertura da terra, monitoramento de florestas e para a agricultura (PEREIRA et al., 2013; LEHMANN et al., 2015; PEREIRA et al., 2018; STENDARDI et al., 2019). Com o avanço e disponibilidade de dados de forma gratuita das constelações Sentinel-1 (com sensor SAR em banda C) e Sentinel-2 (com o sensor MSI - *Multi Spectral Instrument*), devido a alta frequência de revisita (6 e 5 dias, respectivamente) e resolução espacial (20 m e até 10 m, respectivamente) de ambos, a utilização dos dados obtidos por estes sensores possibilita análises espaço-temporais robustas com informações que agregam características advindas de faixas de comprimento de onda diferentes.

Dado o exposto acima, são necessários estudos visando explorar o uso de séries temporais de dados ópticos e de micro-ondas que possam ser aplicadas ao mapeamento das pastagens de forma frequente, em regiões inseridas no bioma Amazônia. Esse tipo de abordagem tem o potencial de otimizar o mapeamento e monitoramento das pastagens frente ao desmatamento de novas áreas.

1.1 Hipótese

A utilização de dados derivados de séries temporais de imagens de sensoriamento remoto de diferentes fontes (ópticos e de micro-ondas) são mais eficientes para mapear e discriminar pastagens do que dados oriundos de uma única fonte (óptica ou de micro-ondas) num único período no tempo, no âmbito de programas de monitoramento, especialmente em regiões com cobertura frequente de nuvens.

Baseado nesta hipótese, com este trabalho de dissertação se objetiva primeiramente investigar o potencial de dados derivados de séries temporais de imagens de sensoriamento remoto dos satélites Sentinel-1 e Sentinel-2 para o mapeamento, discriminação e obtenção de indicativos de qualidade das pastagens na região sul do Estado de Roraima, visando o apoio à programas de monitoramento da Amazônia. São considerados três conjuntos de dados distintos. O primeiro conjunto é composto apenas com imagens do sensor óptico (Sentinel-2), já o segundo conjunto, apenas com imagens SAR (Sentinel-1) e, por fim, o terceiro será composto de imagens tanto ópticas quanto de microondas.

Pode-se ainda vislumbrar como objetivos secundários deste trabalho:

- a) Avaliar os atributos derivados de séries temporais que melhor expressam a separabilidade entre classes de pastagem e outras classes de uso e cobertura da terra.
- b) Avaliar os atributos derivados de séries temporais que melhor expressam a separabilidade entre diferentes tipos de pastagem.
- c) Gerar indicativos de qualidade das pastagens.
- d) Gerar um mapa de pastagens representativo para a área de estudo conforme a metodologia estabelecida.

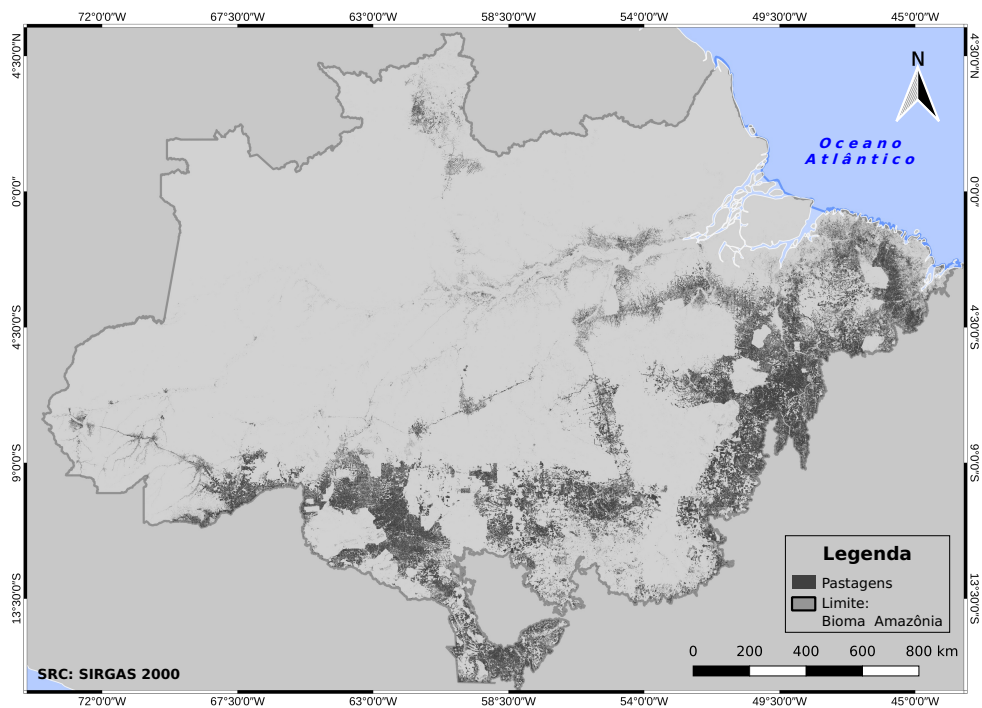
2 FUNDAMENTAÇÃO TEÓRICA

2.1 Pastagens na Amazônia

Nos últimos anos, a evolução da atividade pecuária na região Norte do Brasil tem se intensificado ao contrário das outras regiões do país (IBGE, 2019). O menor custo de produção associado a menor pressão agrícola são fatores que contribuem para este fim, ao contrário das regiões Centro-Oeste, Sudeste e Sul, onde as terras possuem preço mais elevado. Além das condições climáticas do Trópico Úmido, que facilitam o manejo da pastagem em virtude das poucas variações de temperatura ao longo do ano e períodos secos menos severos (DIAS-FILHO; ANDRADE, 2006).

Para Graetz (1991) a ocorrência de pastagens está relacionada à ambientes com precipitação suficiente para o crescimento de gramíneas e a combinação de condições climáticas e/ou antropogênicas para inibição do crescimento de árvores. Na Figura 2.1 é possível observar, destacado em cinza escuro, a distribuição espacial das pastagens para o bioma Amazônia no ano de 2018, segundo a classificação executada pelo MapBiomas.

Figura 2.1 - Distribuição espacial das pastagens pelo bioma Amazônia, para o ano de 2018.



Fonte: Adaptado de Mapbiomas (2020).

A rápida expansão das pastagens pode estar associada à utilização das terras por pouco tempo, em virtude do rápido decaimento da produtividade ao longo do tempo, devido à falta de manejo adequado (NUMATA et al., 2000). Segundo Venturieri (2017) a ocorrência de pastagens degradadas gera grandes prejuízos econômicos e ambientais, tornando-se essencial reverter esta degradação para que haja um ganho na produtividade no campo e conseqüentemente sejam reduzidos os desmatamentos para criação de novas pastagens.

Para Dias-Filho (2017), a degradação da pastagem é definida pela queda acentuada e contínua da produtividade da pastagem, no decorrer do tempo. Este autor define em sua obra que a degradação pode se dar de duas formas: agrícola e/ou biológica. A degradação agrícola é definida quando:

[...] ocorre um aumento excessivo do percentual de plantas daninhas na pastagem. [...] a capacidade produtiva do pasto fica temporariamente diminuída ou inviabilizada, por causa da competição pelas plantas daninhas no capim e nas leguminosas forrageiras. Essa competição reduz sucessivamente a produção de forragem e a eficiência de uso da pastagem pelo gado [...] (DIAS-FILHO, 2017).

Com relação a degradação biológica, esta é definida quando:

[...] a queda de produtividade da pastagem está principalmente associada à deterioração do solo. Nesse caso, há um aumento na proporção de solo descoberto (sem vegetação) na área da pastagem, facilitando a erosão, a perda de matéria orgânica e de nutrientes do solo [...] (DIAS-FILHO, 2017).

Ainda segundo Dias-Filho (2017), os estágios de degradação podem ser sumarizados em quatro (Leve, Moderado, Forte e Muito Forte) considerando uma perda na sua capacidade de suporte (CS). A capacidade de suporte, por sua vez, é dada pelo número de animais que um pasto consegue manter por área, sem obter prejuízos no desenvolvimento do animal e da pastagem.

Para o estágio leve de degradação, considera-se uma perda de 20% na CS da pastagem. No estágio moderado, entre 30% e 50%. Para o estágio forte, entre 60% e 80%. Já no estágio muito forte, a perda na CS é acima de 80%. Pode-se dizer que nos dois primeiros estágios, são considerados pastagens em processo de degradação, e nos dois últimos as pastagens podem ser consideradas degradadas (DIAS-FILHO, 2017).

Instituições como a EMBRAPA, INPE, IBGE e UFG desenvolvem trabalhos específicos quando se trata de pastagens e da sua importância econômica, social e ambiental. Portanto, na Seção 2.2, é exposto como as pastagens são definidas no escopo destes trabalhos.

2.2 Classificação de pastagens

Para o IBGE (2019) as pastagens são classificadas em 3 tipos: pastagem natural, plantada em boas e em más condições de uso. Constitui-se como pastagem natural: “[...] a área de pasto não plantado, mesmo que tivesse sido objeto de limpeza, gradeação etc, utilizada ou destinada ao pastejo dos animais existentes no estabelecimento”. Já as áreas de pastagem plantada em boas condições de uso, que incluem pastagens em processo de recuperação consistem em: “[...] área plantada ou em preparo para o plantio de espécies vegetais, destinada ao pastejo dos animais existentes no estabelecimento, e que não estava degradada, pois recebera manutenção frequente”.

Constituem-se como áreas de pastagem plantada em más condições de uso (degradada ou sem uso):

[...] área plantada com espécies vegetais, destinada ao pastejo dos animais existentes no estabelecimento, considerada nestas condições pelo próprio produtor. Inicialmente produtiva, tal pastagem assumirá esta condição devido à ausência de manutenção ou ao uso intensivo, podendo apresentar outros problemas, como erosão, plantas invasoras e cupinzeiros (IBGE, 2019).

No escopo do projeto TerraClass as pastagens são divididas em dois tipos: pastagem cultivada arbustiva e pastagem cultivada herbácea. É tida como pastagem cultivada arbustiva “[...] aquelas que tem predomínio de vegetação lenhosa, composta por espécies arbustivas/arbóreas, além das espécies herbáceas cultivadas”. Já a pastagem cultivada herbácea são “[...] aquelas com predomínio de vegetação forrageira herbácea, composta por espécies cultivadas” (ALMEIDA et al., 2016; EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA); INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE), 2020). Nesta pesquisa serão adotados estes conceitos.

Com relação a projeto MapBiomass, este não diferencia os tipos de pastagem para o bioma Amazônia, havendo uma única classe para representação da “Pastagem” que é definida como áreas de pastagens, naturais ou plantadas, vinculadas a atividade agropecuária. Há também uma classe chamada “Mosaico de agricultura e pastagem” que incluem áreas onde não foi possível distinguir entre os usos de “Agricultura” e

“Pastagem” (MAPBIOMAS, 2020).

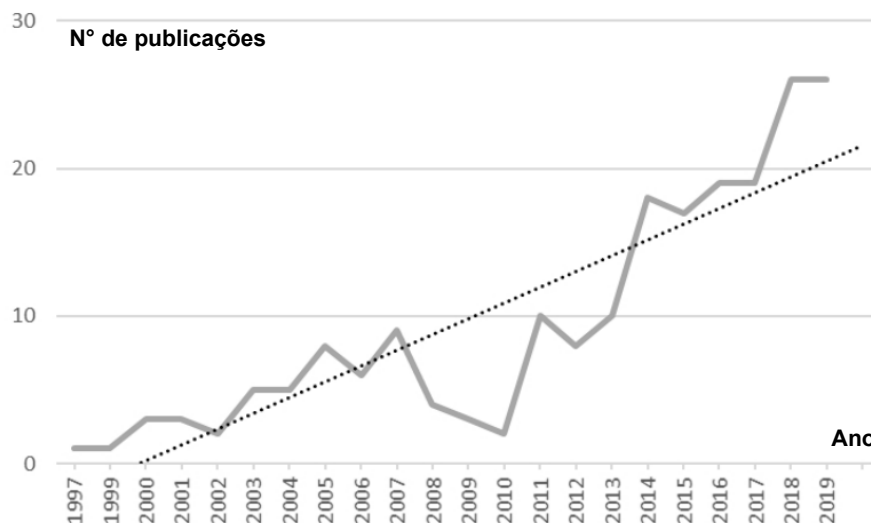
Baseado em tais definições, é fato que a classificação de pastagens executada por essas instituições possuem limitações com relação a seu estágio de degradação, havendo certa generalização das classes. Até a data desta pesquisa, apenas o MapBio-
mas apresenta um produto em fase de testes acerca da degradação das pastagens. Na Seção 2.3, são levantadas bibliografias que envolvem a identificação e discriminação dos pastos por meio da análise de imagens obtidas por sensoriamento remoto.

2.3 Identificação e discriminação de pastagens com sensoriamento remoto

2.3.1 Sensoriamento remoto óptico

Uma pesquisa no repositório da *Science Direct* foi realizada a fim de avaliar o número de publicações ao longo dos últimos anos envolvendo os termos *Remote Sensing*, *Time series* e *Pasturelands* e seu resultado é evidenciado na Figura 2.2, que mostra uma tendência crescente no interesse e relevância do tema por parte da comunidade científica.

Figura 2.2 - Número de publicações por ano, utilizando as palavras-chave *Remote Sensing*, *Time series* e *Pasturelands* no repositório da *Science Direct*.



Fonte: Elaborado pelo Autor.

Na pesquisa desenvolvida por [Abdon et al. \(2009\)](#), quatro níveis de degradação de pastagens (leve, moderada, forte e muito forte) são mapeados em uma dada região estado do Mato Grosso do Sul (MS). Por meio do uso das técnicas de classificação MAXVER (máxima verossimilhança) e *Bhattacharya* em uma imagem fusionada do *China-Brazil Earth-Resources Sattelite* (CBERS-2B), resultado da fusão de cenas provenientes dos sensores CCD e HRC (com resolução espacial de 20 m e 2,5 m, respectivamente), foi obtido um produto temático na escala de 1:50.000. Os autores reiteram a dificuldade de se diferenciar os níveis de degradação sem a adoção de um critério para padronizar as proporções dos elementos que compõem as classes de pasto, devida a alta taxa de confusão obtida entre as classes.

O uso de redes neurais é avaliado por [Chagas et al. \(2009\)](#) comparativamente ao algoritmo de classificação por MAXVER para classificar níveis de degradação (leve, moderado, forte e muito forte) em pastagens no município de Viçosa, MG. Utilizando imagens do sensor ASTER (15 m de resolução espacial), foram adotados três diferentes níveis de degradação para as pastagens (moderado, forte e muito forte). Segundo os autores, estatisticamente não houve mudanças significativas (nível de significância - $\alpha = 5\%$) entre o uso de redes neurais ou o algoritmo Maxver na classificação das classes adotadas. Para ambas as classificações, o nível de degradação “forte” foi bastante confundido com o “muito forte”.

A inclusão da banda espectral referente a borda do vermelho (red edge), compreendido entre 680 - 730 nm, é relatada nos estudos de [Ali et al. \(2016\)](#) como responsável por uma melhora na acurácia da classificação de pastagens manejadas em relação a de pastagens naturais. Então, o uso de sensores multi espectrais presentes nos satélites que possuem tal banda (e.g., RapidEye e Sentinel-2) torna-se factível, juntamente com atributos espaciais que o considerem.

É plausível afirmar que o aumento da resolução espectral pode aumentar o poder de discriminação de um alvo numa simples tomada no tempo, dado que associado a este aumento, ocorre o aumento dos atributos espaciais (neste caso, bandas). Contudo, a inclusão da variável correspondente a fenologia (relações entre os ciclos biológicos com o clima, neste caso inserido por meio do aumento de observações no tempo) pode contribuir significativamente na discriminação deste com as demais classes na ausência de atributos espaciais. Ao entender a dinâmica das pastagens (i.e., clima, regime de chuvas e de manejo), a possibilidade de diferenciá-la de outras classes de uso e ocupação do solo é aumentada.

Pesquisas utilizando índices de vegetação para a identificação e discriminação de

diferentes níveis de degradação em pastagens têm sido desenvolvidas como é possível verificar em [Andrade et al. \(2013b\)](#) e em [Andrade et al. \(2013a\)](#). Cabe destacar que em [Andrade et al. \(2013a\)](#) foram utilizados dados de séries temporais do *Normalized Difference Vegetation Index* - NDVI ([ROUSE et al., 1974](#)) derivado do produto *SPOT-Vegetation* (VGT-S10) com uma síntese de 10 dias e resolução espacial de ± 1 km. A análise foi baseada no coeficiente angular derivado a partir da regressão linear de uma série temporal do NDVI, no período entre 2006 e 2011, e os indicativos de degradação foram observados quando o coeficiente angular foi negativo. Ambos os trabalhos recomendam a utilização de séries temporais longas e de campanhas de campo para se aprimorar a detecção dos processos de degradação de pastagens.

As séries temporais densas de imagens proveniente de sistemas sensores ópticos como os da série *Landsat* e do *Moderate-Resolution Imaging Spectroradiometer* (MODIS) vem sendo bastante utilizados juntamente com o algoritmo de classificação RF na predição de cenários. Nos estudos de dinâmicas temporais das pastagens e no seu posterior mapeamento na Amazônia brasileira, foram obtidas acurácias acima de 80% ([PARENTE et al., 2017](#); [PARENTE; FERREIRA, 2018](#); [PARENTE et al., 2019](#); [JAKIMOW et al., 2018](#)).

[Parente et al. \(2017\)](#) utilizaram um conjunto de 380 imagens Landsat-8, referente ao ano de 2015, que compreendeu a janela temporal do segundo semestre de 2014, até o final do primeiro semestre de 2016, para geração de um mapa de pastagem para todo o território brasileiro. Foram computadas métricas espaço temporais que foram classificadas por meio do algoritmo RF. As bandas do verde, vermelho, infravermelho próximo além dos índices NDVI, *Normalized Difference Water Index* (NDWI) e o *Cellulose Absorption Index* (CAI) foram utilizados na análise. Os resultados obtidos para as classes de “pastagem” e “não-pastagem” atingiram cerca de 87% de acurácia.

A partir da utilização de dados MODIS, [Parente e Ferreira \(2018\)](#) verificaram a dinâmica espacial de ocupação das pastagens brasileiras baseado na classificação automática por meio do algoritmo RF para os anos de 2000 à 2016. A metodologia utilizada neste trabalho é bem similar ao trabalho anterior ([PARENTE et al., 2017](#)). Contudo a adição de dois novos índices é realizada. Estes são o *Enhanced Vegetation Index* (EVI2) e o *Aerosol Free Vegetation Index* (ARFI). O conjunto de amostras de treinamento diferencia as classes de “pastagem” e “não-pastagem”. A acurácia global obtida pelo método, para a geração dos 17 mapas de pastagem, foi de aproximadamente 80%.

Jakimow et al. (2018) também corroboram com essa assertiva nos seus estudos utilizando séries temporais de dados Landsat com o algoritmo de classificação RF para classificar as pastagens na Amazônia brasileira, mais especificamente no estado do Pará, município de Novo Progresso. Por meio de métricas espaço temporais, a classificação executada pelos autores teve como objeto de estudo as classes pasto manejadas com o uso de fogo ou com arado (*burned pasture* e *tilled pasture*). Suas acurácias variam entre 63% e 98% nos diferentes cenários preditos. Por fim, os autores afirmam que em trabalhos futuros o uso de imagens do satélite Sentinel-2 é recomendado no mapeamento das pastagens, visto sua melhor resolução espacial, bandas espectrais diferentes e maior revisita.

O uso de informações derivadas de séries temporais de imagens Sentinel-2, visando uma atuação pioneira voltada para o monitoramento de pastagens na Amazônia brasileira, pode então ser considerada importante em virtude da sua aquisição sistemática e dos dados possuírem resoluções espacial e temporal de 10 *m* e 5 dias, respectivamente (ESA, 2013). Estas características, juntamente com a combinação de bandas espectrais referentes a faixa compreendida pela borda do vermelho (*red edge*), teoricamente aumentam o poder de discriminação de alvos e a possibilidade de obter maiores aquisições livres de nuvens.

Ainda assim, a utilização de dados multifonte se apresenta como uma alternativa para aumentar o número de observações utilizáveis, tendo em vista a alta cobertura de nuvens e considerando a diferente interação da energia com os alvos, proveniente das diferentes características dos sensores utilizados. Na Seção 2.3.2 será abordado como as pastagens estão sendo mapeadas/monitoradas via técnicas de sensoriamento remoto por micro-ondas.

2.3.2 Sensoriamento remoto por micro-ondas

Como citado anteriormente, a utilização de dados ópticos é mais amplamente debatida na literatura em virtude da interação da onda eletromagnética, no espectro relativo ao visível, com as características biofísicas dos alvos. Contudo, isto só é possível em condição atmosférica e de iluminação favorável. A utilização dos sensores de micro-ondas, apesar de possuírem menos faixas de frequência disponíveis (quando comparados aos sensores ópticos), possuem modos distintos de aquisição, diferentes polarizações e órbitas (ascendente e descendente). Deste modo, em virtude destas diferentes configurações, o realce de diferentes características dos alvos é viabilizado.

Na pesquisa desenvolvida por Wang et al. (2013), o potencial de integração dos da-

dos de três sensores de micro-ondas é avaliado para o monitoramento de pastagens na Austrália. As imagens, provenientes dos satélites *COnstellation of small Sattelites for the Mediterranean basin Observation* (COSMO-SkyMed) – banda X, *Environmental Satellite Advanced Synthetic Aperture Radar* (ENVISAT ASAR) – banda C, e *Advanced Land Observing Satellite Phased Array type L-band Synthetic Aperture Radar* (ALOS/PALSAR) – banda L, foram obtidas na polarização HH (i.e., emitida e recebida em polarização horizontal). Nesta pesquisa, a biomassa, o conteúdo hídrico do solo e da pastagem foram avaliados por meio de uma possível relação linear entre o retroespalhamento da onda eletromagnética emitidas e recebidas destas três frequências com os índices de vegetação obtidos por meio de SR óptico e dados climáticos (NDVI, NDWI, EVI e o *Moisture Index* – MI).

Wang et al. (2013) analisaram aspectos espaço-temporais dos dados SAR com os dados ópticos provenientes do sensor MODIS (em virtude de sua disponibilidade temporal) e do *Thematic Mapper* (TM) presente no Landsat-5 em virtude de sua resolução espacial. Nas três frequências os autores observaram um aumento no retroespalhamento do sinal, em uma pastagem específica, no momento de roçada, e um decréscimo no sinal quando aumentava-se a biomassa do pasto. Outra conclusão observada pelos autores foi a de que os dados na banda X apresentaram maior correlação com os índices de vegetação, numa análise tanto temporal quanto espacial. Entretanto, em virtude da alta variação sofrida com relação ao conteúdo hídrico das folhas e solo, o sinal não se apresentou estável como nas bandas C e L. Os dados na banda C, apresentaram moderada confiabilidade na avaliação da biomassa e do conteúdo hídrico das pastagens, com influência limitada das chuvas no período seco. Os dados na banda L, foram os menos acurados para a mensuração da biomassa dos pastos em virtude de sua forte penetrabilidade e conseqüentemente maior interação com o solo.

Com relação a utilização de séries temporais de imagens de radar para detecção de pastagens, Barrett et al. (2014) propuseram a utilização de dados multissensores, multitemporais e de dados auxiliares para o monitoramento das pastagens na Irlanda. Utilizando abordagens de aprendizado de máquina (*machine learning* – ML) em cenas dos radares ENVISAT e ALOS-PALSAR (banda C e L, respectivamente), os autores avaliaram o desempenho dos classificadores RF, SVM e *Extremely Randomised Trees* (ERT) para a detecção de pastagens no norte da Irlanda, segundo seu manejo. Os melhores desempenhos registrados pelos autores foram em sua maioria para o classificador ERT, utilizando ambas as frequências, obtendo acurácias globais variando de 86,1% a 98,7%, obtendo resultados superiores quando compa-

rados a utilização apenas da informação oriundas de um único sensor de microondas isoladamente.

Abdikan et al. (2016) investigaram o potencial dos dados em polarização VV e em VH do Sentinel-1 usados conjuntamente para o mapeamento da cobertura do solo na Turquia. Com a utilização de uma aquisição simples no tempo e o algoritmo de classificação SVM, os autores conseguiram obter acurácias globais, considerando diferentes cenários por meio da utilização de diferentes atributos oriundos de operações entre as polarizações, acima de 70%. As classes mapeadas foram “água”, “área urbana”, “floresta”, “agricultura” e “campos” (onde os pastos estão incluídos). Uma das conclusões obtida pelos autores foi a de que o atributo de diferença entre as polarizações (VV-VH) contribuiu mais do que atributos que computavam a média ou a razão simples entre as polarizações.

Com relação ao uso de dados Sentinel-1 na Amazônia, Diniz (2019) avaliou o uso do dado dual-pol (VV e VH), por meio da classificação de atributos polarimétricos, interferométricos e de coeficientes de retroespalhamento, para geração de um mapa de uso e cobertura da terra em uma área no município de Ariquemes, em Rondônia. A discriminação das classes ocorreu em duas fases, a primeira objetivando discriminar as classes de pastagem, agricultura e floresta. E a segunda, estratificando as classes de floresta em floresta degradada, floresta primária e sucessões secundárias avançada, intermediária e inicial. Para o melhor cenário gerado, o potencial da coerência interferométrica (γ_{vv}) é destacado pela autora como o atributo que obteve a maior importância relativa no processo de classificação, utilizando a técnica RF, para a classe de pastagem.

Técnicas de *Artificial Neural Networks* (ANN) aplicadas a dados de radar também são utilizadas para monitorar o status de pastagens. Taravat et al. (2019) avaliam a técnica *multilayer perceptron* em dados Sentinel-1, num contexto espaço-temporal, para monitorar o status de pastagens na Alemanha. Utilizando os coeficientes de retroespalhamento das polarizações VH e VV para três datas, além de métricas texturais de segunda ordem como entropia, homogeneidade, contraste e dissimilaridade foi obtido uma acurácia global de 85,71% no seu melhor cenário. Cabe destacar que nos cenários preditos pelos autores, o uso da informação temporal e, principalmente, das métricas texturais aumentaram a acurácia da classificação em 71,43% com relação ao uso apenas da informação pontual (i.e., numa única data) proveniente dos coeficientes de retroespalhamento nas polarizações VV e VH.

Desta forma, é possível observar que o uso de atributos que expressam os dados

de forma espaço-temporal é, teoricamente, capaz de discriminar e monitorar pastagens. Técnicas que possibilitam integrar dados oriundos de sensores ópticos (vide Seção 2.3.1) e de micro-ondas, neste contexto, podem ser empregadas a fim de combinar os ganhos provenientes da informação espectral (dos dados ópticos) e textural (dos dados de micro-ondas). Na Seção 2.3.3 serão mostradas abordagens que promovem a integração de dados ópticos e de micro-ondas assim como seus resultados.

2.3.3 Abordagens com integração de dados

No que diz respeito as técnicas de integração de dados duas principais abordagens emergem da literatura previamente citada: a combinação e a fusão de dados. A primeira refere-se ao empilhamento das bandas corregradas das imagens dos diferentes sensores para processamento posterior, sem a criação de novos atributos. Já a segunda, utiliza técnicas que computam novos atributos considerando as informações provenientes das imagens dos diferentes sensores (PEREIRA et al., 2013; PEREIRA et al., 2018).

Pereira et al. (2013) avaliaram diferentes métodos de integração de dados ópticos e de micro-ondas multipolarizados para o mapeamento do uso e cobertura na Amazônia Brasileira. As classes mapeadas foram referentes a floresta (primária e degradada), regenerações florestais (nova, intermediária e antiga), pastagens (limpa e suja, conceitos equivalentes as definições utilizadas pelo TerraClass) e de agricultura (*fallow*, soja 40 e 100 dias após o plantio). A combinação simples (i.e., o empilhamento das bandas corregradas) de imagens em banda L do ALOS/PALSAR com imagens Landsat-5/TM apresentaram os melhores resultados, em detrimento da técnica de fusão por principais componentes (PCA), aumentando a acurácia do usuário para o mapeamento de duas classes de pastagem. Nesta análise, os autores reportaram que a contribuição do canal HH foi maior que a do canal HV. Entretanto, o uso de ambas as polarizações produz, estatisticamente, resultados melhores do que utilizando apenas uma polarização, produzindo um resultado com acurácia global de 86%.

Num contexto operacional, visando a complementariedade dos dados de sensores ópticos e de radar para um sistema de monitoramento de larga escala de florestas, Lehmann et al. (2015) investigaram, por meio da técnica de análise canônica, o nível de discriminação entre classes de floresta e não-floresta. Ao avaliar a complementariedade destes dados junto a atributos texturais extraídos dos dados de radar (ALOS/PALSAR e RADARSAT-2, sendo o último em banda C) e ópticos (MSS-TM-ETM+/Landsat), os autores relataram que a combinação dos dados Landsat e ALOS proveram uma maior discriminação das áreas de floresta.

Stendardi et al. (2019) propuseram o uso sinérgico de dados Sentinel-2 (ópticos) e Sentinel-1 (micro-ondas) para o monitoramento da fenologia de pastagens em áreas montanhosas na região norte da Itália. Na análise realizada pelos autores, existe uma forte correlação do retroespalhamento do radar, na polarização VH, com o NDVI obtido pela razão das bandas do Sentinel-2, utilizado para a detecção dos estágios fenológicos. Contudo, os autores destacam um decréscimo na acurácia desta correlação à medida em que se aumentam as altitudes das áreas montanhosas, concluindo que o Sentinel-1 é menos eficiente do que o Sentinel-2 na detecção do estágio fenológico relativo ao "início da estação" das pastagens. Entretanto, nas análises realizadas pelos autores, o Sentinel-1 é tido como tão robusto quanto o Sentinel-2 para detecção dos eventos de roçada nas pastagens, concluindo que essa abordagem de integração destes dados é promissora para a detecção da fenologia.

A complexidade de alcançar uma metodologia capaz de processar dados ópticos e de radar, visto as diferenças posicionais e os erros inerentes de cada sistema sensor é alta (LEHMANN et al., 2015). O grande esforço computacional necessário para o processamento do grande volume de dados, associado a tal complexidade relatada pelos autores anteriormente citados, poderia comprometer o caráter operacional do mapeamento. Algo que pode ser gradativamente atenuado com a crescente utilização dos sistemas de computação em nuvem, como o *Google Earth Engine* (GORELICK et al., 2017).

2.4 Técnicas de processamento digital de imagens

Nesta seção são apresentadas descrições resumidas das técnicas de processamento digital de imagens utilizadas no desenvolvimento desta pesquisa.

2.4.1 Filtragem do *speckle*

Dados adquiridos por meio de radares de abertura sintética, em virtude da natureza coerente das micro-ondas, são corrompidos com um ruído multiplicativo conhecido como *speckle* (WOODHOUSE, 2006). A redução deste ruído pode ser considerada uma etapa fundamental ao se trabalhar com dados SAR, visto que este ruído pode dificultar a interpretação adequada do dado em função da aleatoriedade inerente ao sinal.

Diversas técnicas têm sido desenvolvidas visando a redução do *speckle* em imagens SAR baseadas em estatísticas locais e modelos adaptativos. O emprego do processamento *multilook*, técnicas clássicas como a aplicação de filtros espaciais e temporais

estão entre as mais utilizadas (DINIZ, 2019). Para quantificar o desempenho destes filtros, na literatura são encontrados métodos que vão desde a análise visual das imagens anteriores e posteriores ao processo de filtragem (LEE et al., 1994), até a medição de parâmetros estatísticos para aferição da preservação de atributos (como a média) e ganho de informação baseados em métricas proporcionais à relação sinal ruído (i.e., coeficiente de variação, número equivalente de visada, entre outros) (SANT'ANNA; MASCARENHAS, 1996).

No entanto, valores superestimados em estatísticas como o *Equivalent Number of Looks* (ENL), que é uma das métricas mais utilizadas para este propósito, podem ser facilmente obtidas ao se filtrar excessivamente os dados, o que culmina numa perda de detalhes da imagem. Desta forma, avaliar um filtro apenas pela sua capacidade de melhorar tais medidas pode não ser adequada em vista destas limitações (GOMEZ et al., 2017).

Sendo o *speckle* considerado um ruído multiplicativo ($Z = \hat{X} * Y$), Z é a variável que representa o sinal observado pelo sensor, e é visto como o produto de duas outras variáveis aleatórias: o retroespalhamento (X) e o *speckle* (Y). Desta forma, após a aplicação de um filtro em uma imagem SAR, é esperado que um estimador para X , varie com Z . Portanto, ao se considerar uma filtragem ideal, a razão entre o dado observado (Z) e o filtrado (\hat{X}) resultaria apenas no *speckle* (Y). *Speckle* este, que segundo Goodman (1976), pode ser modelado por uma distribuição Gama com média igual 1 e parâmetro de forma igual ao número de *looks* da imagem, para dados no formato intensidade.

Desta forma, novas abordagens para a avaliação do desempenho dos filtros redutores de *speckle* surgem baseadas na razão entre o dado observado (não filtrado) e o dado filtrado. Esta análise permite, além da checagem visual (para visualizar se há a presença de estruturas geométricas remanescentes da imagem original), a avaliação da mudança de propriedades estatísticas dos alvos, o que pode indicar uma mau desempenho do filtro aplicado.

Proposto por Gomez et al. (2017), o índice \mathcal{M} é uma métrica que considera medidas obtidas por meio da imagem razão. Este índice expressa a partir da soma de duas componentes ponderadas, o desempenho de filtros redutores de *speckle*. A primeira componente é baseada em estatísticas de primeira ordem (a fim de avaliar a preservação da média e do ENL) e a segunda, está relacionada com estatísticas de segunda ordem (visando avaliar a presença de geometrias remanescentes), ambas para a imagem razão. Na Equação 2.1 é detalhada a formulação da métrica \mathcal{M} :

$$M = \omega * r_{E\hat{N}L,\hat{\mu}} + k * \delta_h * (1 - \omega) \quad (2.1)$$

onde ω corresponde ao peso atribuído para a ponderação das variáveis. Esta variável tem por objetivo indicar o grau de importância atribuído a cada uma das componentes; $r_{E\hat{N}L,\hat{\mu}}$, a primeira componente, que descreve a média dos valores absolutos dos resíduos análogos à preservação da média e ENL; k , ao coeficiente para escalar a variável δ_h , tornando-a assim comparável com a primeira componente; e δ_h corresponde a segunda componente, que descreve a variação relativa de estruturas remanescentes na imagem razão, baseadas na homogeneidade (atributo de textura de Haralick).

Para o cálculo da primeira componente é necessária a identificação de $n > 1$ áreas homogêneas na cena, de onde se extrai:

$$r_{E\hat{N}L,\hat{\mu}} = \frac{1}{2} \sum_{i=1}^n (r_{E\hat{N}L}(i) + r_{\hat{\mu}}(i)) \quad (2.2)$$

com,

$$r_{E\hat{N}L}(i) = \frac{|E\hat{N}L_{noisy}(i) - E\hat{N}L_{ratio}(i)|}{E\hat{N}L_{noisy}(i)} \quad (2.3)$$

representando o valor absoluto dos resíduos relativos aos desvios do ENL ideal, e $r_{\hat{\mu}}(i) = |1 - \hat{\mu}_{ratio}(i)|$ refere-se ao valor absoluto dos resíduos relativos aos desvios da média ideal. $E\hat{N}L_{noisy}$ corresponde ao valor ENL calculado sobre a imagem não filtrada, enquanto $E\hat{N}L_{ratio}$ corresponde ao valor ENL calculado sobre a imagem razão. Já o cálculo da segunda componente (Equação 2.4) consiste no cômputo do resíduo estrutural na imagem razão. Para tal, são computados o atributo de homogeneidade de Haralick na imagem razão e em suas versões permutadas. Estas versões permutadas consistem na reordenação dos *pixels* aleatoriamente na imagem.

$$\delta_h = \frac{|h_0 - h_g|}{h_0} \quad (2.4)$$

Onde h_0 corresponde a média dos valores de todos os *pixels* da imagem de homogeneidade obtidos da imagem razão e; h_g representa a média dos valores de todos os *pixels* obtidos das versões permutadas desta imagem. Estudos mais aprofunda-

dos acerca do índice \mathcal{M} e suas propriedades estatísticas podem ser encontrados em Gomez et al. (2017) e em Gomez et al. (2019).

2.4.2 Técnicas de classificação

Nos algoritmos de classificação mais usuais nos *softwares* de processamento de imagens, a distribuição gaussiana é adotada como modelo de distribuição dos dados, algo que não é recomendado para o dado de radar em virtude do ruído *speckle* (BARRETT et al., 2014). Deste modo, o uso de algoritmos de aprendizado de máquina podem ser mais recomendados dado que nestes não se considera distribuição a priori dos dados. O aprendizado de máquina é uma abordagem empírica eficaz para realizar regressões e/ou classificações (supervisionadas ou não) de sistemas não-lineares, oferecendo potencial no âmbito do sensoriamento remoto (LARY et al., 2016).

Visto que estas técnicas podem modelar assinaturas complexas de classes, aceitar uma grande variedade de dados de entrada para a predição, e não admitem distribuição a priori para os dados, algoritmos de aprendizado de máquina vêm sendo utilizados amplamente na literatura recente de sensoriamento remoto (MAXWELL et al., 2018). A classificação pelo algoritmo *Random Forests* (RF) (BREIMAN, 2001) vem ganhando destaque, por apresentar excelentes resultados no que diz respeito a acurácia de resultados de classificação (BELGIU et al., 2016; DINIZ; GAMA, 2019; SICA et al., 2019).

O algoritmo *Random Forests* é um estimador supervisionado baseado numa combinação de classificadores por árvores de decisão, que ajusta suas decisões baseado em subamostras do conjunto de dados e usa a média destas para melhorar a precisão da sua predição, controlando e evitando o sobreajuste (*overfitting*). Sua relevância nas últimas décadas ocorre devido aos excelentes resultados de classificação e regressão, além de possuir um alto desempenho computacional no processamento de grandes conjuntos de dados, sendo amplamente empregado nas pesquisas realizadas pela comunidade científica (BELGIU et al., 2016; DINIZ, 2019; SICA et al., 2019).


Na classificação de pastagens, as contribuições obtidas por Carneiro et al. (2020), Parente et al. (2019) evidenciam o poder de discriminação do algoritmo RF com relação a outras classes de uso e ocupação do solo com acurácias reportadas na ordem de 90%. Deste modo, o modelo de classificação empregado nesta pesquisa será o modelo *Random Forests*.

2.4.3 Síntese de séries temporais

No estudo de séries temporais, a dinâmica da informação temporal pode ser analisada por meio da transformação, classificação, álgebra e/ou interpretação visual dos dados. Comumente, são aplicados redutores estatísticos a fim de se obter métricas que consigam descrever fenômenos que diferenciem alvos. A síntese das séries temporais por meio de redutores, além de otimizar os processos computacionais devido a redução do volume de dados de entrada no processo de classificação, pode tornar o processo mais assertivo uma vez que pode se optar pela entrada de dados sem redundância.

Dentre as possibilidades de síntese, estas podem ser obtidas a partir de métricas lineares e polares (KÖRTING, 2012). São entendidas como métricas lineares, estatísticas como a média, desvio-padrão, valor mínimo, valor máximo entre outras estatísticas descritivas do conjunto de dados. As métricas polares podem ser obtidas após projetar uma série temporal para um espaço polar (KÖRTING et al., 2013). Para tanto, é necessária a transformação dos valores da série temporal em coordenadas polares garantindo que estes criem uma geometria fechada. Desta forma, podem ser estimados parâmetros como a área da geometria, bem como sua excentricidade, balanço polar, desvio de forma entre outros. Na Figura 2.3 é mostrado um esquema para computação dos atributos na série temporal em função de uma geometria polar.

Figura 2.3 - Associação de valores de uma série temporal a determinado ângulo (esquerda), geometria fechada formada a partir da transformação dos valores para um plano polar (direita).



Fonte: Körting et al. (2013).

Além destas técnicas de síntese de séries temporais, ainda é possível estimar parâ-

metros relacionados a distribuições específicas de cada tipo de dado. Deste modo, é conhecido o fato de que os dados ópticos, em virtude do seu ruído ser aditivo (diferente do radar onde adota-se o ruído multiplicativo) são por natureza aderentes a distribuição normal. Contudo, para os dados SAR esta realidade é diferente com ressalvas para diferentes formatos (intensidade ou amplitude, por exemplo).

O teste estatístico de Kolmogorov-Smirnov (KS) pode ser empregado nestes casos para verificar a aderência de conjuntos de dados à distribuições estatísticas. Dado o modelo multiplicativo dos dados, no formato em intensidade, o teste KS, foi usado para testar a aderência dos dados de radar à distribuição Gama, cuja função de densidade de probabilidade para uma variável aleatória X é expressa por:

$$f(x; \kappa; \theta) = \frac{x^{\kappa-1} e^{-\frac{x}{\theta}}}{\theta^{\kappa} \Gamma(\kappa)} \text{ para } x > 0 \text{ e } \kappa, \theta > 0 \quad (2.5)$$

onde os parâmetros correspondem, respectivamente, aos parâmetros de forma e escala da função Gama.

Para estimar os parâmetros da distribuição Gama, várias formas podem ser encontradas na literatura desde métodos mais consagrados como o Estimador de Máximo Verossimilhança (MLE), Método dos Momentos entre outros. Nesta pesquisa, optou-se por utilizar o método *Closed Form* proposto por [Ye e Chen \(2017\)](#). Neste método, os parâmetros são derivados com base no MLE, todavia são ponderados para que não haja tendência. Os estimadores $\hat{\kappa}$ e $\hat{\theta}$ são obtidos pelas expressões 2.6 e 2.7.

$$\hat{\kappa}_0 = \frac{N \sum_{i=1}^N x_i}{N \sum_{i=1}^N x_i \ln(x_i) - \sum_{i=1}^N \ln(x_i) \sum_{i=1}^N x_i} \quad (2.6)$$

$$\hat{\theta}_0 = \frac{1}{N^2} \left(N \sum_{i=1}^N x_i \ln(x_i) - \sum_{i=1}^N \ln(x_i) \sum_{i=1}^N x_i \right) \quad (2.7)$$

E a correção para a tendência é dada por

$$\hat{\kappa} = \hat{\kappa}_0 - \frac{1}{N} \left(3\hat{\kappa}_0 - \frac{2}{3} \left(\frac{\hat{\kappa}_0}{1+\hat{\kappa}_0} \right) - \frac{4}{5} \frac{\hat{\kappa}_0}{(1+\hat{\kappa}_0)^2} \right) \quad (2.8)$$

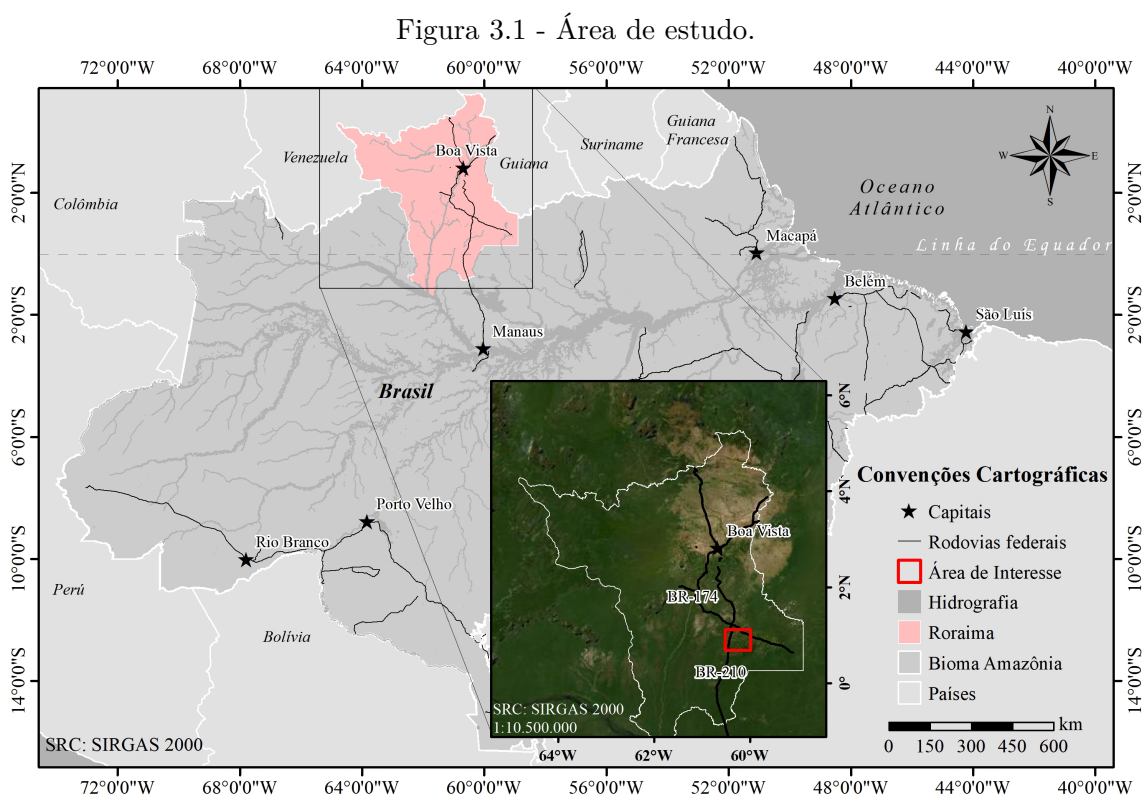
$$\hat{\theta} = \frac{N}{N-1} \hat{\theta}_0 \quad (2.9)$$

Dado o exposto na literatura levantada, a utilização de algoritmos de classificação não-paramétricos associados a dados combinados de sensoriamento remoto, óptico e de micro-ondas, podem gerar resultados promissores. A utilização de atributos que consigam expressar aspectos espaço-temporais pode auxiliar na representação da dinâmica de classes de uso e cobertura da Amazônia brasileira, visando discriminar diferentes classes de pastagens. Deste modo, na Seção seguinte são descritos os materiais e métodos utilizados nesta pesquisa.

3 MATERIAL E MÉTODOS

3.1 Caracterização da área de estudo

A área de estudo (Figura 3.1) localiza-se entre os municípios de Rorainópolis e São Luiz, na região Sudeste do estado de Roraima. O estado de Roraima, por sua vez está inserido no bioma Amazônia e faz parte do grupo de estados que compõem a Amazônia Legal. Em virtude de o estado estar inserido em sua maioria no hemisfério norte, o período de maior incidência de chuvas e secas são ligeiramente diferentes daqueles do restante do bioma. Todavia para a porção sudeste, que está sob maior influência do regime climático amazônico, seu período seco é compreendido de dezembro a março e o chuvoso de abril a novembro (XAUD, 2013).



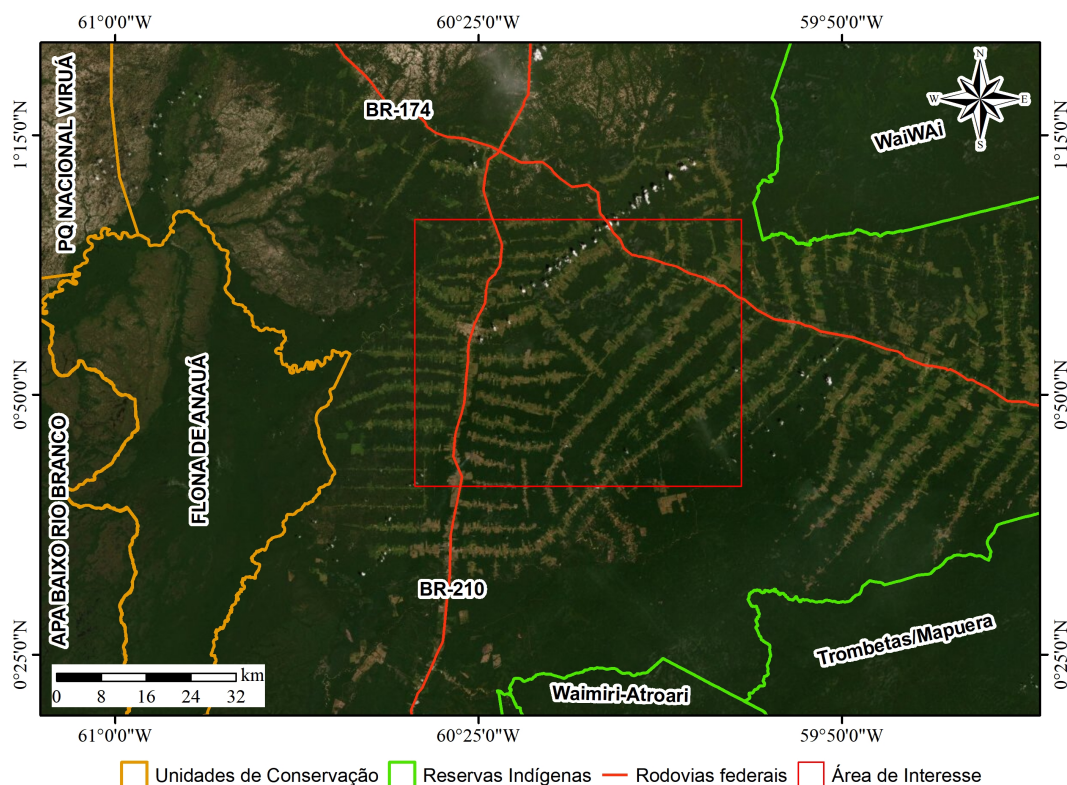
Fonte: Elaborado pelo autor.

O estado é composto majoritariamente por florestas nativas, formações não-florestais (características de cerrado) e pastagens, segundo o mapeamento mais recente executado pela iniciativa MapBiomas, para o ano de 2019 (MAPBIOMAS, 2020). O clima, segundo a classificação de Köppen (KÖPPEN; GEIGER, 1928), é predominantemente “Am”. A precipitação na região varia de 2.200 a 2.800 mm por ano. O relevo é predo-

minantemente plano, compreendido em até 200 m de altitude. No entanto, nas suas latitudes mais altas – fronteira com Venezuela e Guiana – as altitudes são superiores à 800 m, onde situa-se o Monte Roraima (ALVARES et al., 2013).

O monitoramento da região de estudo pode ser considerado particularmente estratégico dada a sua proximidade com terras indígenas e áreas de preservação. Na Figura 3.2 são demonstrados os limites da área de estudo da pesquisa, bem como os limites das unidades de conservação e terras indígenas mais próximas. Ao considerar tais fatores, o monitoramento de pastagens torna-se essencial visto que esta área encontra-se sob bastante pressão em decorrência das grandes extensões de terra voltadas para atividades agropecuárias. Cortada pelas BR-174 e BR-210, esta região possui tráfego intenso, em decorrência de interligar as capitais Boa Vista e Manaus (BR-174) assim como interligam o extremo Sul e Sudeste de Roraima com o restante do estado (BR-210).

Figura 3.2 - Proximidade da área de estudo em relação a unidades de conservação e reservas indígenas.



Fonte: Elaborado pelo autor.

3.2 Dados

Os dados utilizados para o desenvolvimento desta pesquisa incluem conjuntos de imagens de sensoriamento remoto (SR) e dados de campo, tais como pontos coletados com equipamentos *Global Navigation Satellite System* (GNSS), imagens de alta resolução provenientes de sensores embarcados em Aeronaves Remotamente Pilotadas (ARPs) além de fotografias e informações gerais. A campanha de campo ocorreu no período de 09/03/2020 à 13/03/2020. Os dados de SR que compõem o conjunto de dados são imagens dos sensores embarcados nos satélites Sentinel-1 e Sentinel-2.

Os dados de SR obtidos compõem uma janela temporal de dois anos, garantindo o predomínio de dados para o ano de referência, no caso 2019 (com imagens de julho/2018 até junho/2020). Esta janela temporal permite a obtenção de uma série temporal mais densa para a geração das métricas temporais, o que a torna capaz de registrar, de forma mais adequada, a variação do vigor vegetativo das pastagens e variações climáticas, dado que os pastos são alvos bastante susceptíveis a tais variações (FERREIRA et al., 2013).

3.2.1 Sentinel-1

O Sentinel-1, lançado em abril de 2014 (Sentinel-1A) e abril de 2016 (Sentinel-1B), é um sistema sensor de micro-ondas que opera em banda C, com diferentes modos de aquisição, que incluem o modo *Interferometric Wide Swath* (IW). Este modo de aquisição é indicado para aplicações de mapeamento de uso e cobertura e possui uma resolução espacial de 5 x 20 m em range e azimuth, respectivamente. Neste modo, o sensor adquire as imagens em duas polarizações, que podem ser HH e HV ou VV e VH, com uma faixa de imageamento de 250 km e um intervalo de revisita de seis dias, considerando os dois satélites (ESA, 2013). O método IW, com aquisição nas polarizações VV e VH foi o escolhido para a pesquisa.

No conjunto de dados do Sentinel-1, alguns pré-processamentos são executados nos dados para obtenção das imagens ortorretificadas e calibradas para o coeficiente de retroespalhamento (σ_0). O σ_0 pode ser descrito como uma medida normalizada para a intensidade de cada pixel. Dentre os pré-processamentos estão inclusos: remoção dos ruídos de borda e termais, calibração radiométrica e ortorretificação (GOOGLE EARTH ENGINE (GEE), 2018). Para a ortorretificação, são utilizados modelos digitais de elevação do SRTM 3 arco de segundo para as órbitas onde existam a disponibilidade deste e a imagem é disponibilizada com tamanho de pixel de 10 m. Contudo para atender a componente com resolução mais baixa, foi feita uma reamostragem

no dado, resultando num dado com tamanho de pixel de 20 m. Cabe salientar que há uma limitação no poder de análise dos dados em virtude do conjunto de dados ser disponibilizado com o dado já calibrado, inviabilizando análises em atributos extraídos a partir da informação de fase da onda. Ainda assim, o acesso rápido e eficiente promovido pelo Google Earth Engine (GEE) para estes dados fomenta a utilização destes para o teste de diferentes metodologias.

3.2.2 Sentinel-2

O Sentinel-2, lançado em junho de 2015 (Sentinel-2A) e em março de 2017 (Sentinel-2B), são satélites gêmeos que possuem um sensor multiespectral (*Multispectral Scanner Instrument* - MSI) com 13 bandas, variando de 400 à 2.200 nm aproximadamente. Dentre suas características, cabe destacar que este sensor possui 4 diferentes bandas espectrais para a faixa referente ao red edge, além de bandas referentes ao azul, verde, vermelho e infravermelho próximo com resoluções espaciais distintas, variando de 10 à 60 m. A constelação possui um intervalo de revisita de cinco dias, considerando os dois satélites (ESA, 2015). Suas bandas estão descritas na Tabela 3.1.

Tabela 3.1 - Bandas espectrais do Sentinel-2A (S2A) e Sentinel-2B (S2B).

Nome	δ (m)	λ (nm)
B1 (Aerossóis)	60	443, 9 (S2A) / 442, 3 (S2B)
B2 (Azul)	10	496, 6 (S2A) / 492, 1 (S2B)
B3 (Verde)	10	560 (S2A) / 559 (S2B)
B4 (Vermelho)	10	664, 5 (S2A) / 665 (S2B)
B5 (Borda do vermelho 1)	20	703, 9 (S2A) / 703, 8 (S2B)
B6 (Borda do vermelho 2)	20	740, 2 (S2A) / 739, 1 (S2B)
B7 (Borda do vermelho 3)	20	782, 5 (S2A) / 779, 7 (S2B)
B8 (Infravermelho Próximo)	10	835, 1 (S2A) / 833 (S2B)
B8A (Borda do vermelho 4)	20	864, 8 (S2A) / 864 (S2B)
B9 (Vapor d'água)	60	945 (S2A) / 943, 2 (S2B)
B11(Infravermelho de ondas curtas 1)	20	945 (S2A) / 943, 2 (S2B)
B12 (Infravermelho de ondas curtas 2)	20	2202, 4 (S2A) / 2185, 7 (S2B)

δ = Resolução espacial. λ = Comprimento de onda.

Fonte: ESA (2015).

Visando manter periodicidade, órbita e características consistentes, para a execução desta pesquisa foi utilizado um conjunto de imagens SAR do sensor abordo do satélite Sentinel-1A. Para o Sentinel-2, o nível de processamento do dado utilizado foi o Level-2A (L2A) que corresponde ao dado em superfície de reflectância (SR).

O conjunto de dados utilizados para compor as séries temporais, óptica e SAR, utilizadas na pesquisa estão descritos na Tabela 3.2.

Tabela 3.2 - Características das imagens utilizadas para a construção das séries temporais.

	Sentinel-1	Sentinel-2
Satélite (sensor)	S1A (C-band SAR)	S2A e S2B (ambos MSI)
Órbita relativa* (<i>tiles</i> na grade)	38480/83	22530/53 (20NQG, 20NQF 20NRG, 20NRF)
Tamanho de pixel (m)	20	
Horário de passagem aproximada (UTC)	09:45	14:30
Intervalo temporal	01-07-2018 à 30-06-2020	
Nº de imagens (aquisições)	60	145
Bandas	VV e VH	B3, B4, B5, B6, B7, B8, B8A, B11 e B12
Nível de processamento	GRD (IW)	L2A
Direção de imageamento	Descendente	

* Equivalente ao conceito de órbita-ponto prevalente nas imagens da constelação Landsat.

Fonte: Elaborado pelo autor.

Deste modo, foram utilizadas 60 imagens SAR, ou seja 120 canais (60 para cada polarização). Bem como, da mesma forma, foram utilizados 9 canais de 145 imagens ópticas, que totalizam 1305 canais.

3.2.3 Trabalho de campo

A campanha de campo objetivou fornecer subsídios para conhecimento, treinamento e validação dos dados gerados pela pesquisa. Para a definição das classes a serem discriminadas, diferentes amostras de pastagens foram coletadas em campo. Com base nestas amostras, foram definidas duas classes a priori: Pastagem Herbácea e Pastagem Arbustiva, cujas definições encontram-se na Seção 2.2, em concordância com o projeto TerraClass. Na Figura 3.3 estão dispostos os pontos visitados em campo com amostras de diferentes pastagens.

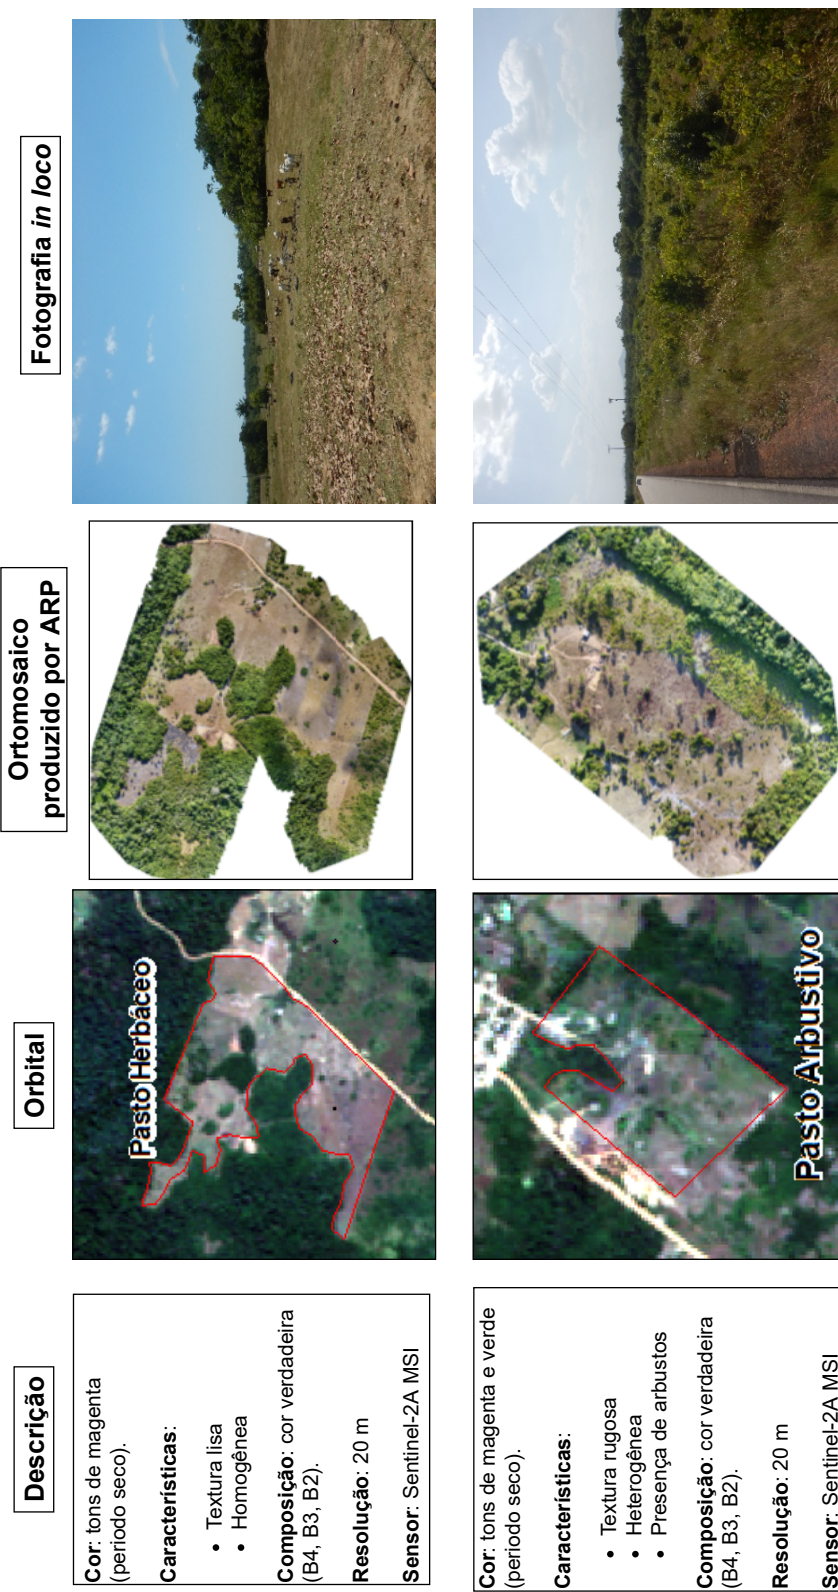
Figura 3.3 - Pontos de GNSS das pastagens visitadas em campo.



Fonte: Elaborado pelo autor.

Para a densificação de amostras, uma chave de interpretação foi criada para detecção das pastagens em imagens de sensoriamento remoto, com o sensor presente no Sentinel-2, com auxílio dos dados de campo. Na Figura 3.4 é apresentada uma descrição de como essas duas classes de pastagens ocorrem na imagem de satélite, acompanhados de imagens para exemplificar a ocorrência destas em escalas diferentes (Orbital, ARP e fotografia *in loco*).

Figura 3.4 - Chave de interpretação para as classes de pastagem Herbácea e Arbustiva.




Fonte: Elaborado pelo autor.

Na Figura 3.5 é evidenciada a distribuição dos pontos densificados pela área de estudo baseados na chave de interpretação, incluindo os pontos coletados em campo, totalizando 100 pontos para pastagens (sendo 53 pontos para Pastagens Herbáceas e 47 para Pastagens Arbustivas). A imagem de referência utilizada para densificação dos pontos foi uma imagem que representa uma mediana das imagens obtidas pelo sensor Sentinel-2/MSI com resolução de 20 m para o período de 23 de fevereiro à 28 de março de 2020 a fim de coincidir com o período de campo. Foi optado pela estatística referente à mediana devido à menor probabilidade de se considerar no cálculo *pixels* com a ocorrência de nuvens ou sombras de nuvem.

Cabe salientar que as amostras (pontos) foram obtidas de forma a evitar bordas e/ou transições entre diferentes classes, para que não haja contribuição do efeito de borda na aquisição dos valores. Foram considerados imageamentos obtidos até 15 dias antes e 15 dias depois do período de campo, para obtenção de cenas com menor alterações possíveis.

Figura 3.5 - Distribuição espacial dos pontos de campo juntamente com pontos gerados com base na chave de interpretação.







Fonte: Elaborado pelo autor.

3.2.4 Mapas de uso e cobertura do solo

Dentre os dados auxiliares utilizados para o melhor entendimento da dinâmica de uso e ocupação da área de estudo, mapas de uso e cobertura do solo foram obtidos dos projetos TerraClass e Mapbiomas. Estes mapas foram combinados afim de se obter amostras de classes presentes em ambos os mapeamentos (desconsiderando a pastagem, pois foi coletada em campo e densificada a partir de interpretação visual), tornando-as assim mais consistentes. Para tanto, foi necessário compatibilizar as legendas dos mapeamentos realizando algumas generalizações de classes.

É importante salientar que ambos os mapeamentos são realizados com base em coleções de cenas Landsat, com resolução espacial de 30 m. Entretanto, suas metodologias se diferem e, por conseguinte, suas classes também. Desta forma, na área de estudo abordada nesta pesquisa, as classes predominantes mapeadas pelo projeto TerraClass (no ano de 2014) correspondem às classes de "Vegetação natural florestal primária", "Vegetação natural florestal secundária", "Pastagem cultivada arbustiva", "Pastagem cultivada herbácea", "Área urbanizada", "Corpos d'água" e "Não-observado". Já para o projeto Mapbiomas (para o ano de 2019), as classes predominantes são "Formação florestal", "Pastagem", "Infraestrutura urbana" e "Rio, lago e oceano". Na Tabela 3.3 são apresentadas as classes com suas respectivas legendas e a correspondência feita entre os mapeamentos.

Tabela 3.3 - Correspondência de classes predominantes presentes nos mapeamentos de uso e cobertura do solo para a área de estudo.

TerraClass 2014	Mapbiomas 2019
Vegetação natural florestal primária Vegetação natural florestal secundária	 Formação florestal
Pastagem cultivada arbustiva Pastagem cultivada herbácea	 Pastagem
Área urbanizada Não observado	 Infraestrutura urbana
Corpos d'água	 Rio, lago e oceano

Em negrito, a nomenclatura adotada para as classificações subsequentes.

Fonte: Elaborado pelo autor.

Em suma, além das diferenças temáticas e de método, é importante destacar a desconexão temporal dos mapeamentos. Até a data da presente pesquisa, o último mapeamento disponível no TerraClass para a área de estudo é referente ao ano de


2014. Enquanto que, para o Mapbiomas, o último mapeamento disponível é para o ano de 2019, ano de referência adotado para esta pesquisa. Contudo, apesar da diferença temporal dos mapeamentos, após a compatibilização das legendas, ao realizar a combinação destes mapas é possível obter classes consistentes (invariantes) ao longo do tempo.

A classe "Não observado" presente no mapeamento executado pelo TerraClass em 2014 não obteve nenhuma correspondência com o mapeamento executado pelo Mapbiomas em 2019 por tratar-se de uma classe que corresponde à áreas recobertas por nuvens e/ou sombras de nuvem na época do mapeamento. Para esta classe em específico, foi tratada como área fora da combinação (presente no resultado da combinação dos dois mapas).

Um total de 50 pontos, referente à combinação das legendas pertinentes à "Formação florestal", "Área urbanizada" e "Corpos d'água" foram coletados para compor a **Etapa 1** do processo de classificação. Esta etapa consiste em classificar as principais classes de uso e cobertura do solo elencadas para a área de estudo com três conjuntos distintos de dados, que correspondem aos dados derivados das séries temporais ópticas, de radar e da combinação destas. Nesta etapa, as classes de pastagem serão agrupadas e consideradas como apenas "Pastagem" a priori. Desta forma, totalizam-se 250 pontos. Na Figura 3.6 estão ilustrados os mapeamentos de uso e ocupação do solo, bem como o resultado da combinação destes, após a compatibilização das legendas, que estão dispostas na Tabela 3.3.

Adicionalmente, após a execução da Etapa 1, o resultado pertinente à classe de pastagem será reclassificado com o intuito de estratificar a classe em "Pastagem arbustiva" e "Pastagem herbácea". Esta etapa será referida no decorrer do documento como **Etapa 2** a partir deste ponto.

Figura 3.6 - Mapas de uso e cobertura do solo utilizados para a área de estudo: A) Terra-
Class 2014; B) MapBiomass 2019 e C) Combinação dos mapeamentos.



* As áreas de cor preta correspondem a áreas não concordantes entre os mapeamentos.

Fonte: Elaborado pelo autor.

3.3 Processamento dos dados

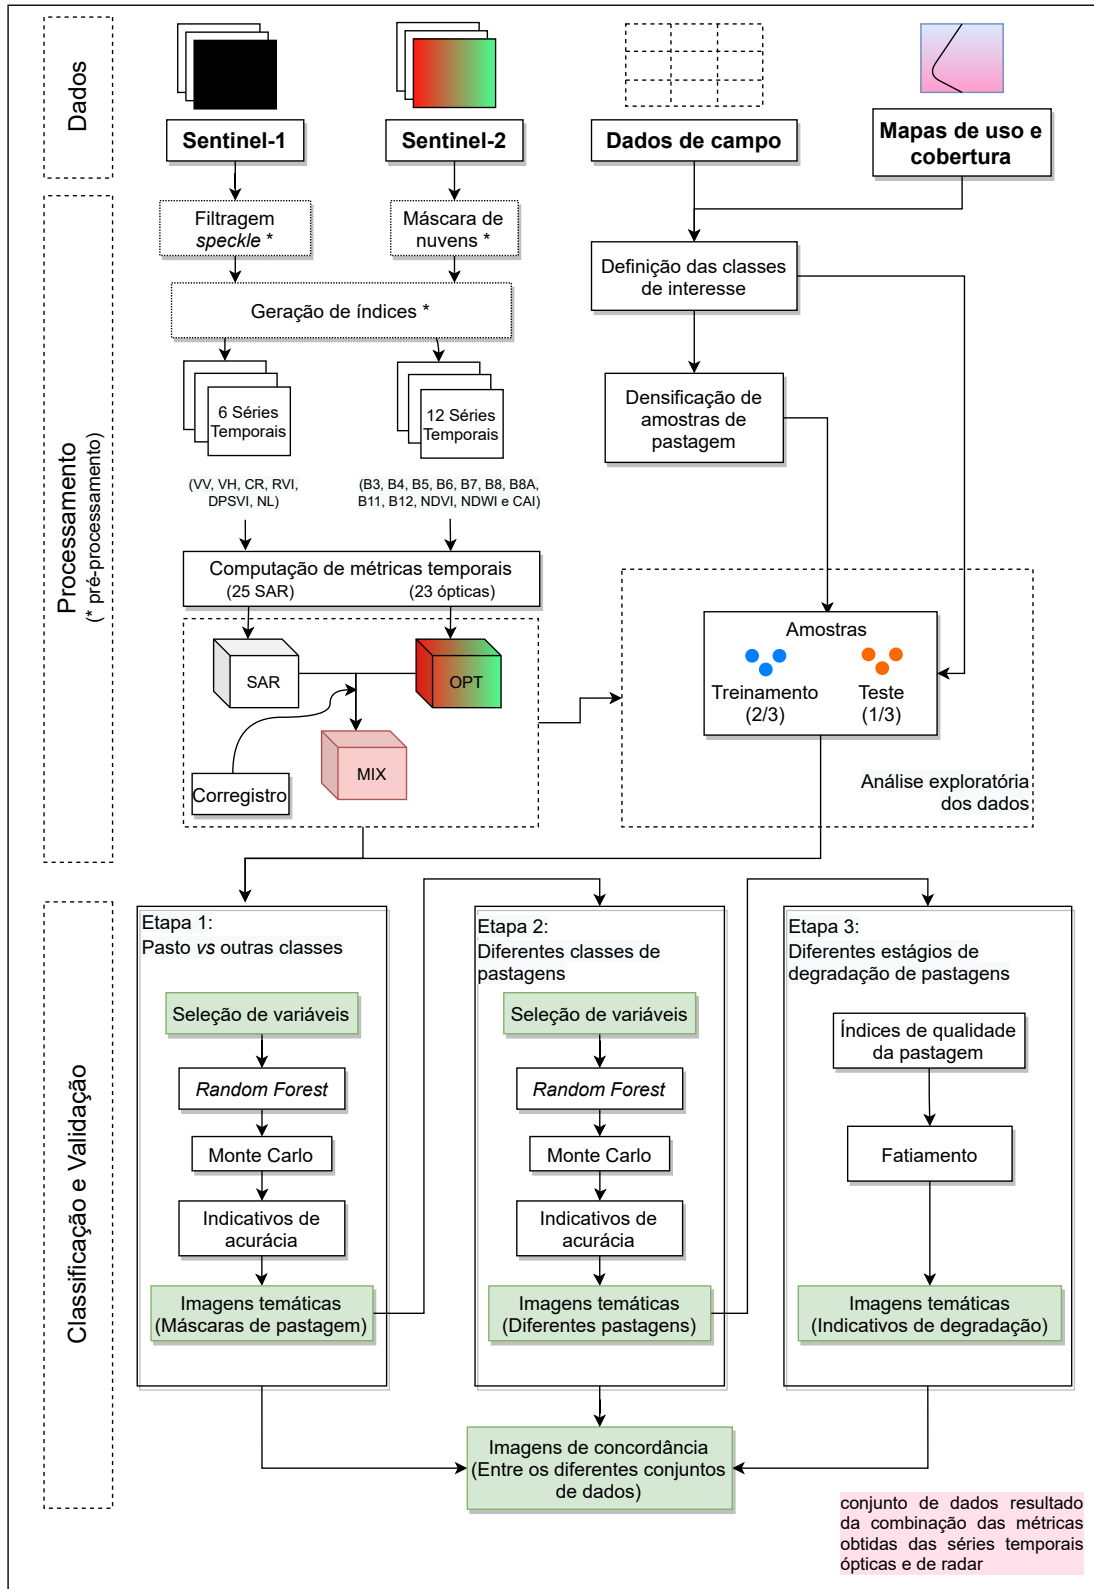
Nesta seção são detalhados os processos referentes a metodologia adotada para o desenvolvimento da pesquisa. Na Figura 3.7 é esquematizado o fluxo metodológico, que é organizado em três fases distintas: i) referente aos diferentes tipos de dados de entrada (já descritos anteriormente), chamada Dados; ii) relativo à preparação, manipulação dos dados de entrada e geração de conjuntos de atributos, denominada de Processamento e iii) relativo à identificação e discriminação das classes de interesse, denominada de Classificação e Validação.

A fase de Processamento é subdividida, para as imagens de radar, na filtragem de *speckle*, geração de índices utilizando a informação dos canais VV e VH e computação de métricas temporais, resultando no conjunto de atributos a ser utilizado para a fase de Classificação e Validação. Para as imagens ópticas, esta fase consiste em mascarar as nuvens presentes nas imagens, gerar índices espectrais utilizando a informação das bandas compreendidas no espectro do vermelho, infravermelho próximo e de ondas curtas e computação das métricas temporais, resultando no conjunto de atributos ópticos para serem utilizados na fase de Classificação e Validação. Por fim, estes conjuntos de atributos resultantes são corregrados para dar origem a um terceiro conjunto de dados que integra os atributos gerados pelos conjuntos ópticos e de radar, que também serão utilizados na fase de Classificação e Validação.

Para os dados de campo e mapas de uso e cobertura esta etapa consistiu na utilização destes insumos para a definição das classes de interesse, bem como a densificação das amostras de pastagem para serem utilizadas como amostras de treinamento e teste na etapa de Classificação e Validação dos dados.

Já a fase de Classificação e Validação dos dados é dividida em três etapas distintas: i) que consiste na seleção de variáveis à serem classificadas, no processo de classificação pelo algoritmo *Random Forest*, para obtenção de imagens temáticas diferenciando a classe de Pastagem das demais; ii) na seleção de variáveis à serem classificadas, no processo de classificação pelo algoritmo *Random Forest*, para obtenção de imagens temáticas estratificando a classe de Pastagem em Arbustiva e Herbácea e iii) na geração de indicativos de qualidade das Pastagens obtidas na Etapa 2.

Figura 3.7 - Fluxograma de procedimentos.



Fonte: Elaborado pelo autor.

3.3.1 Filtragem de *speckle*

Para a escolha do filtro redutor de *speckle* adequado para o cenário proposto nesta pesquisa, optou-se por realizar uma análise incluindo os filtros mais simples (Média e Mediana) até aqueles com técnicas mais robustas, como os propostos por Frost et al. (1982) (Frost), Baraldi e Parmiggiani (1995) (Gamma MAP), Lee (1981) (*Refined Lee*) e de médias não-locais. Para esta última abordagem, foi utilizado o filtro desenvolvido por Torres et al. (2012), no qual utilizou distâncias estocásticas para determinar a similaridade entre as amostras não-local e central, para computação de uma média não local visando a redução do *speckle* (Stochastic Distance Non-Local Means - SDNLM). Também foi testado o filtro temporal proposto por Quegan e Yu (2001) em combinação com os filtros espaciais anteriormente citados, excetuando-se o filtro SDNLM. Devido ao filtro SDNLM utilizar médias não-locais e da técnica proposta por Quegan e Yu modificar a média das imagens, não seria adequado associá-los.

Desta forma, esta análise teve como objetivo encontrar o filtro que obtém o melhor desempenho na redução do ruído para esta situação. Portanto, foi utilizado o índice \mathcal{M} proposto por Gomez et al. (2017) descrito na seção 2.4.1. As implementações foram conduzidas nos ambientes de programação em nuvem utilizando a plataforma do *Google Earth Engine*, para computação e extração dos dados e a linguagem de programação R para geração dos gráficos e análise dos dados.

3.3.2 Máscara de nuvens

Para utilização do conjunto de dados ópticos, foi necessária a aplicação de uma máscara de probabilidade de nuvens. Tal procedimento visa atenuar a influência que tais constituintes atmosféricos possam ter no processo de classificação. Uma máscara pré-computada e disponibilizada pela ESA para os produtos processados no nível *L2A* foi utilizada para este fim. Nesta pesquisa o limiar adotado para a probabilidade de nuvens foi de 10% (i.e., os alvos que apresentam uma probabilidade acima de 10% de serem nuvens foram mascarados). De forma complementar, visando compatibilizar o conjunto de dados ópticos com o de radar, suas bandas foram reamostradas para 20 *m*.

3.3.3 Geração de índices

Para os dados SAR, com o intuito de realçar a informação contidas nas imagens com diferentes polarizações, foram computados quatro índices que integram a informa-

ção proveniente das diferentes polarizações das imagens SAR: o *Cross-Ratio* (CR), *Radar Vegetation Index for Sentinel-1* (RVI) (MANDAL et al., 2020), o *Dual Polarization SAR Vegetation Index* (DPSVI) (PERIASAMY, 2018) e, por fim uma adaptação do índice *NL* proposto por Lu et al. (2011). Para o cálculo destes índices, foram consideradas informações de intensidade da onda. Estes índices são dados por:

$$CR = \frac{\sigma_{VH}^0}{\sigma_{VV}^0} \quad (3.1)$$

$$RVI = \sqrt{dop} * \frac{4\sigma_{VH}^0}{\sigma_{VV}^0 + \sigma_{VH}^0} \quad (3.2)$$

$$dop = \frac{\sigma_{VV}^0}{\sigma_{VV}^0 + \sigma_{VH}^0}$$

$$DPSVI = \frac{\sigma_{VV}^0 + \sigma_{VH}^0}{\sigma_{VV}^0} \quad (3.3)$$

$$NL = \frac{\sigma_{VV}^0 * \sigma_{VH}^0}{\sigma_{VV}^0 + \sigma_{VH}^0} \quad (3.4)$$

Já para as imagens ópticas, dada a relevância do registro das interações entre as bandas do vermelho e infravermelho no mapeamento de uso e cobertura do solo, foram computados os seguintes índices: *Normalized Difference Vegetation Index* - NDVI (ROUSE et al., 1974), *Normalized Difference Water Index* - NDWI (GAO, 1996) e o *Cellulose Absorption Index* - CAI (NAGLER et al., 2003). Estes índices são dados por:

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (3.5)$$

$$NDWI = \frac{\rho_{NIR} - \rho_{SWIR_1}}{\rho_{NIR} + \rho_{SWIR_1}} \quad (3.6)$$

$$CAI = \frac{\rho_{SWIR_1}}{\rho_{SWIR_2}} \quad (3.7)$$

onde ρ refere-se a reflectância em cada banda presente nas equações, *RED* é referente a banda do vermelho, com faixa de comprimento de onda central em aproximadamente 664 nm, *SWIR₁* e *SWIR₂* referem-se as bandas do infravermelho de ondas

curtas com comprimentos de onda central em aproximadamente 945 nm e 2200 nm , respectivamente. Em virtude destes índices estarem relacionados, respectivamente, com o vigor vegetativo, com o status hídrico da vegetação (além da detecção de corpos hídricos) e com a profundidade média de absorção de celulose, tornam-se importantes na discriminação das diferentes classes de uso e cobertura da terra.

3.3.4 Métricas temporais

Após a computação dos índices de vegetação elencados na seção anterior, são adicionadas a série temporal de imagens ópticas 3 canais, totalizando 12 canais de informação no volume de dados. Para cada canal, um total de 145 aquisições foram coletadas, conforme descrito na tabela 3.2. Já para as séries de radar, 4 novos canais são adicionados, totalizando 6 canais, dos quais possuem 60 aquisições cada ao longo do tempo. Desta forma, as métricas temporais foram computadas no eixo do tempo, por *pixel*, para cada canal.

Dentre as métricas utilizadas para descrever as séries temporais, estão estatísticas como a média, somatório, desvio padrão, valor mínimo, valor máximo, range (i.e., diferença absoluta entre o máximo e o mínimo), percentis (p_{10} , p_{25} , p_{75} e p_{90}), mediana, prange (i.e., diferença entre o p_{90} e p_{10}) e o coeficiente de variação (que corresponde a razão entre o desvio-padrão e a média). Estas métricas são denominadas como estatísticas básicas.

Métricas polares também foram extraídas para compor o espaço de atributos utilizado para as classificações. Para tanto, foi necessário projetar as séries temporais para um espaço polar visando compor uma geometria fechada para posterior extração de métricas como a área desta geometria, por exemplo. Para realizar o cômputo destas métricas foi utilizado a biblioteca *stmetrics* (SOARES et al., 2020) disponível na linguagem de programação *python*. As métricas polares utilizadas foram a área da geometria, ângulo, área dos quadrantes (Q_1 , Q_2 , Q_3 e Q_4), Balanço polar, Excentricidade, Raio de giro e CSI.

Além destas métricas citadas anteriormente, como tentativa de melhor discriminar a classe de pastagem das demais, as séries temporais de pastagens, nos dados SAR, foram ajustadas após o teste estatístico de Kolmogorov-Smirnov (KS) à distribuição Gama, de forma que fosse possível obter os parâmetros de forma e escala desta distribuição, para cada pixel. Deste modo, duas métricas temporais adicionais foram computadas para os canais de imagens SAR. Portanto, como resultado da computação das métricas, as séries temporais ópticas foram reduzidas a um conjunto de

23 métricas para cada canal e as séries temporais de radar foram reduzidas à 25 métricas para cada canal, totalizando 276 atributos derivados das séries temporais ópticas e 150 atributos derivados das séries temporais de radar. Um terceiro conjunto de dados ainda foi gerado com base na combinação das métricas derivadas das séries temporais de dados ópticos e de radar, este conjunto é composto de 426 atributos. Na Tabela 3.4, estão sumarizadas as métricas utilizadas neste estudo.

Tabela 3.4 - Métricas utilizadas no processo de classificação.

Básicas	Média	Média aritmética dos valores da série
	Somatório	Somatório dos valores da série
	Desvio-padrão	Desvio-padrão dos valores da série
	Mínimo	Valor mínimo da série
	Máximo	Valor máximo da série
	Range	Diferença absoluta entre o valor máximo e mínimo da série temporal
	Percentis	p_{10} , p_{25} , p_{75} e p_{90} dos valores da série temporal
	Mediana	Mediana da série temporal
	prange	Diferença absoluta entre os valores p_{90} e p_{10}
	Coeficiente de variação	Razão entre o desvio-padrão e a média
Polares	Área	Área da geometria fechada
	Ângulo	Ângulo principal da forma criada pela visualização polar
	Área dos quadrantes	Área parcial da geometria, proporcional aos quatro quadrantes da representação polar (Q_1 , Q_2 , Q_3 e Q_4)
	Balanco polar	Desvio-padrão das áreas por quadrante
	Excentricidade	Relacionado a forma da geometria, retorna próximo a 0 quando a geometria se aproxima de um círculo e 1 se a geometria se aproxima de uma linha
	Raio de giro	Corresponde a distância média entre cada ponto dentro da forma e o seu centróide
	CSI	Medida adimensional associada a morfologia da geometria. Caracteriza o desvio-padrão do objeto para um círculo
Parâmetros da distribuição Gama	Forma (κ)	Parâmetro de forma da distribuição Gama. Valores altos indicam aproximação a uma distribuição normal
	Escala (θ)	Parâmetro de escala da distribuição Gama

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

3.3.5 Corregistro

Para criação do conjunto de dados combinados e posterior geração dos mapas de diferenças das classificações, foi necessário realizar o corregistro dos conjuntos de dados ópticos e de radar. O corregistro garante que os *pixels* de imagens de diferentes fontes, correspondam posicionalmente no espaço geográfico (SILVA et al., 2012). Desta forma, os conjuntos de atributos ópticos e de radar foram empilhados e, em seguida, corregistrados.

3.3.6 Análise exploratória dos dados para a seleção de variáveis

Com o intuito de explorar o comportamento dos dados, assim como suas características estatísticas, essa análise de comportamento das classes visa definir os atributos que melhor descrevem a separabilidade das classes. Nesta etapa foram avaliados os comportamentos das diferentes classes que compõem a paisagem presentes na área de estudo.

Após a determinação das classes de interesse e da densificação das amostras baseado na chave de interpretação, foram gerados *boxplots* associados com gráficos de séries temporais das classes. Visando estimar o poder de discriminação dos atributos, foi utilizada como critério de separabilidade a distância de Jeffries-Mattusita (JM), descrita na Equação 3.8 (RICHARDS; JIA, 2006). Esta distância, quando parametrizada pela distância estocástica de Bhattacharya (b), tem como propósito mensurar, num espaço finito compreendido entre 0 e $20^{0,15}$, a distância entre duas distribuições estatísticas.

$$JM_{(x,y)} = \sqrt{2 \left(1 - e^{-b_{(x,y)}}\right)} \quad (3.8)$$

onde b , segundo Coleman e Andrews (1979), corresponde

$$b_{(x,y)} = \frac{1}{4} \ln \left[\frac{1}{4} \left(\frac{\sigma_x^2}{\sigma_y^2} + \frac{\sigma_y^2}{\sigma_x^2} + 2 \right) \right] + \frac{1}{4} \left[\frac{(\mu_x - \mu_y)^2}{\sigma_x^2 + \sigma_y^2} \right] \quad (3.9)$$

com μ_i e σ_i representando respectivamente a média e o desvio-padrão da variável aleatória $i (i \in x, y)$ de distribuição gaussiana.

No entanto, a formulação da Equação 3.8 considera apenas a distância entre duas distribuições. Supondo uma situação multiclasse com n classes, a distância JM

média pode ser computada através da média de todas as distâncias numa combinação das classes tomadas duas a duas (PEREIRA, 2012). A distância JM média é dada por:

$$\overline{JM}_p = \frac{1}{C_{n,2}} \sum_{x,y=1(x<y)}^n p \cdot JM_{x,y} \quad (3.10)$$

Visando a seleção de um subconjunto otimizado de atributos para a classificação, foi construída uma matriz de correlação utilizando a informação dos atributos presentes nas amostras das classes, com o intuito de reter apenas aqueles que melhor diferenciam as classes e que sejam descorrelacionados entre si. Desta forma, para a execução deste procedimento foi montado um algoritmo para ordenar os atributos pela sua distância JM média, selecionar o atributo com maior distância JM média e reter apenas os atributos que, com relação à ele, possuíam correlação inferior à 0,60. Sucessivamente, o próximo atributo com maior JM média foi analisado e o processo de exclusão dos atributos foi repetido. Destaca-se que o processo foi repetido até que o subgrupo de atributos retidos possuíssem valores de correlação inferior a 0,60 entre si.

3.4 Método de classificação e avaliação

3.4.1 *Random Forest*

O algoritmo *Random Forest* é um estimador supervisionado baseado numa combinação de árvores de decisão. Por sua vez, este estimador é capaz de ajustar suas decisões baseado em subamostras do conjunto de dados e tem sido amplamente empregado para a classificação e predição de dados, visto seus excelentes resultados no âmbito da classificação de imagens, como é apresentado na seção 2.4.2. Desta forma, o modelo de classificação utilizado foi o disponibilizado na biblioteca *scikit-learn* (PEDREGOSA et al., 2011) implementado na linguagem de programação *python*.

Na determinação dos parâmetros de classificação, foi utilizado o método *RandomizedSearchCV*. Esta estratégia consiste na busca por parâmetros otimizados utilizando conceitos de validação cruzada ao treinar e validar o modelo com diferentes parâmetros, retornando ao final uma configuração ótima, segundo parâmetros de acurácia, evitando-se o sobreajuste do modelo. Essa estratégia se diferencia da busca exaustiva basicamente pelo número de operações, onde a busca exaustiva permeanha uma combinação de todos os parâmetros encadeados. Na estratégia utilizada são escolhidas diferentes combinações de parâmetros de forma randômica a serem

testados. Foram testadas 100 combinações diferentes para 10 “folds” de validação cruzada, resultando em 1000 ajustes.

Os valores fornecidos para o teste de cada parâmetro do modelo estão dispostos na Tabela 3.5, com os parâmetros selecionados destacados em negrito. Dentre os parâmetros testados estão o número de árvores (nt), número mínimo de amostras necessárias para dividir um nó interno (mss), número mínimo de amostras necessárias para cada nó externo ($mssl$), número máximo de atributos para dividir um nó (mf) e a máxima profundidade de árvore (md). Os parâmetros selecionados foram os mesmos utilizados para todas as etapas de classificação e para os diferentes conjuntos de dados.

Tabela 3.5 - Parâmetros de entrada para a execução do algoritmo *RandomizedSearchCV*. Em destaque, estão os parâmetros ótimos elencados pela técnica.

Parâmetros	Valores de entrada no algoritmo
nt	50, 100 , 150, 200, 250, 300, 350, 400, 450 e 500
mf	' log2 ', 'sqrt'
md	1, 2, 3, 4, 5, 6, 7, 8 , 9, 10
mss	1, 2, 3, 4, 5, 6, 7 , 8, 9, 10
mssl	1, 2, 3, 4, 5 , 6, 7, 8, 9, 10

Fonte: Elaborado pelo autor.

3.4.2 Monte Carlo, indicativos de acurácia e imagens de concordância

Após a obtenção dos valores otimizados para a classificação dos conjuntos de dados, para as Etapas 1 e 2 da metodologia de classificação, foi executada a validação dos modelos de classificação. Na validação destes modelos, foram empregados indicativos de acurácia obtidos de um experimento Monte Carlo baseado em 1000 iterações com as amostras de teste.

O experimento Monte Carlo permite o estabelecimento de intervalos de credibilidade de determinada métrica e o cômputo de medidas de tendência central e de dispersão tais como média, desvio-padrão, amplitude, entre outros. Portanto, sua utilização permite ilustrar a variabilidade dos indicativos de acurácia obtidos pelas classificações (LANDAU; BINDER, 2009; ALMEIDA et al., 2010; MARUJO et al., 2017).

Para avaliar se os resultados obtidos nas classificações são estatisticamente diferen-

tes entre si, foi utilizado o teste de McNemar (MCNEMAR, 1947). Este teste baseia-se nos resultados obtidos em uma matriz de contingência 2x2, que representa a proporção de *pixels* que foram classificados de forma correta e incorreta pelas diferentes classificações, de forma pareada. Na Tabela 3.6 é representada a matriz de contingência.

Tabela 3.6 - Exemplo de matriz de contingência.

		Classificação 2		Σ
		Acertos	Erros	
Classificação 1	Acertos	f_{11}	f_{12}	
	Erros	f_{21}	f_{22}	
	Σ			

Fonte: Adaptada de Foody (2004).

Os elementos da matriz de contingência podem ser obtidos a partir dos resultados das classificações, onde segundo Foody (2004), f_{11} corresponde ao número de *pixels* corretamente classificado em ambas as classificações; f_{ij} com $i \neq j$ aos *pixels* que foram corretamente preditos em uma classificação porém erroneamente na outra; e f_{22} representa os *pixels* que foram classificados erroneamente em ambas as classificações.

A hipótese nula proposta no teste de McNemar baseia-se na igualdade de f_{12} e f_{21} , ou seja, que a mesma proporção de *pixels* será corretamente classificada em ambas as classificações. Para avaliar a significância do teste, o valor crítico do teste qui-quadrado pode ser obtido conforme a Equação 3.11. Salienta-se que o valor p foi utilizado para a verificação a um nível de significância de 10 %.

$$\chi^2 = \frac{(f_{12} - f_{21})^2}{f_{12} + f_{21}} \quad (3.11)$$

Como forma de espacializar a concordância obtida pelos diferentes resultados de classificação, foi computada a razão entre os resultados onde a ocorrência do valor 1 indica concordância entre as classificações e, valores menores ou maiores que este, indicam diferenças entre os mapeamentos.

3.4.3 Detecção da degradação

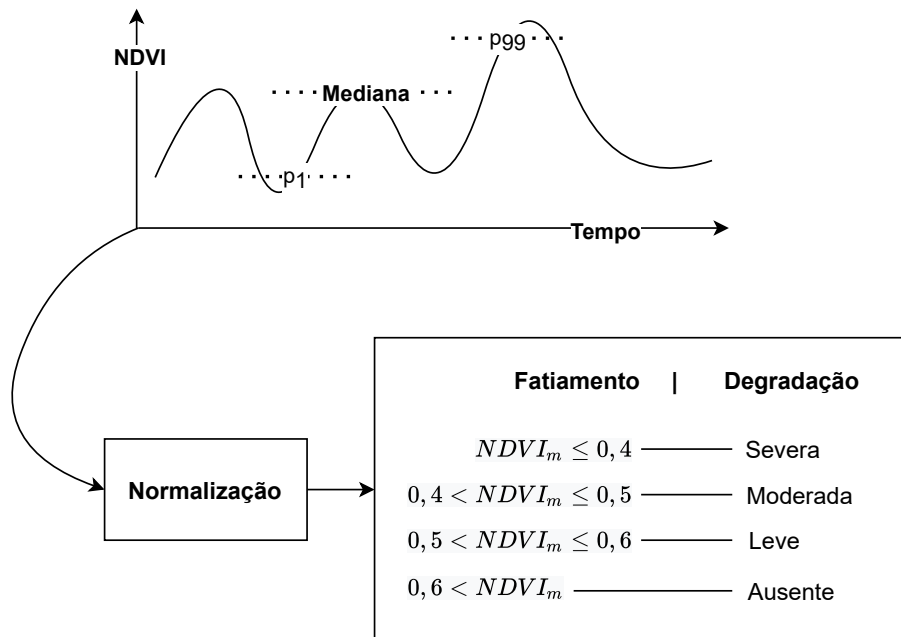
Para se obter indicativos de degradação das pastagens, na literatura são encontradas diferentes metodologias que permeiam desde técnicas mais modestas como a avaliação de índices de vegetação num tempo t_0 específico (ou seja, monotemporal) (ANDRADE et al., 2013b), até análises mais complexas envolvendo o uso de séries temporais de índices de vegetação provenientes de imagens de sensoriamento remoto (ANDRADE et al., 2013a). Desta forma, para esta pesquisa optou-se por utilizar, para a geração de indicativos de degradação, a informação proveniente de séries temporais de sensoriamento remoto por meio da extração de métricas temporais.

Para esta classificação, foram desprezados os valores 1% menores e maiores da série temporal do NDVI para cada pixel. Com os valores restantes, calculou-se a mediana a fim de representar a série temporal neste pixel que, posteriormente, teve seu valor normalizado pelos valores do 1° e 99° percentil desta mesma série (para obtenção de valores aproximadamente entre 0 e 1). Uma vez realizada esta operação para cada pixel da imagem, a intensidade de degradação foi definida em Severa ($NDVI_m \leq 0,4$), Moderada ($0,4 < NDVI_m \leq 0,5$), Leve ($0,5 < NDVI_m \leq 0,6$) e Ausente ($NDVI_m > 0,6$), onde $NDVI_m$ é o valor mediano, normalizado, da série temporal do NDVI aparado em 1%. Este fatiamento do $NDVI_m$ pode ser visualizado graficamente na Figura 3.8.

Para os dados SAR, o processo ocorreu de forma similar ao óptico. No entanto, na ausência de um atributo diretamente relacionado à degradação de pastagens, foi realizada uma regressão linear múltipla com relação ao $NDVI_m$, utilizando um conjunto de atributos SAR. Para seleção dos atributos, foi utilizada a técnica *stepwise* onde foram adicionados e removidos os atributos da equação de modo que restaram apenas aqueles atributos que apresentaram um aumento na explicação do modelo (i.e., aumento do coeficiente de determinação).

Para o conjunto de dados combinados, o método utilizado foi o mesmo para os dados ópticos. Tendo em vista que o método utilizado no conjunto de dados SAR foi uma regressão para aproximar-se dos dados ópticos, optou-se por manter a prevalência, caso haja, dos dados ópticos.

Figura 3.8 - Procedimentos para obtenção de indicadores de degradação de pastagens baseado em séries temporais de NDVI.

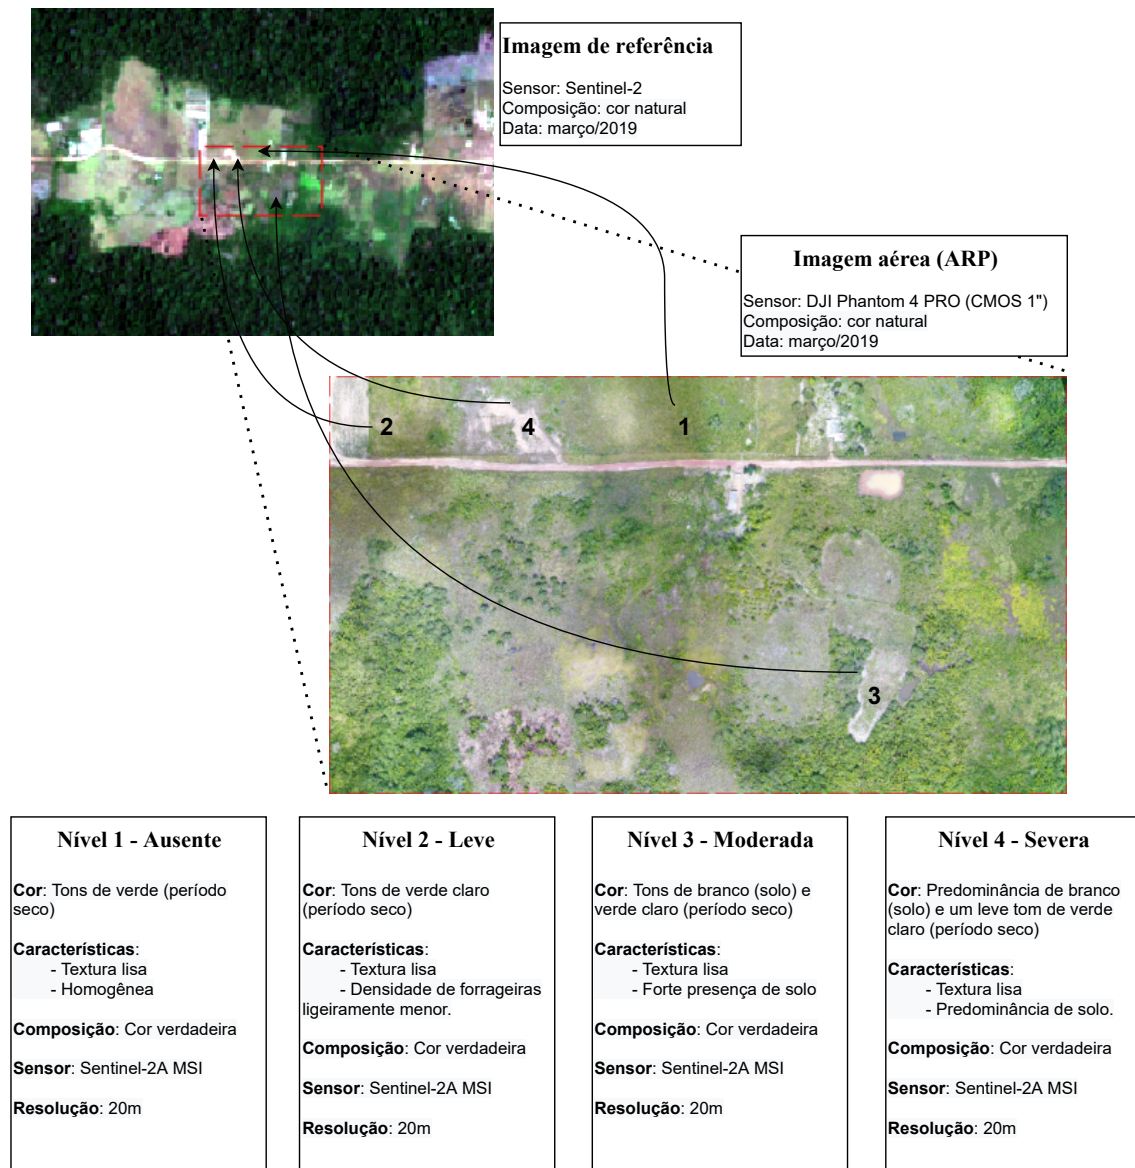


Fonte: Elaborado pelo autor.

Para a validação destes indicadores de degradação, os dados obtidos em campo (anotações, pontos GNSS e imagens aéreas obtidas por ARP) foram fundamentais na definição das classes das amostras. De forma similar a chave de interpretação gerada para densificar as amostras de Pastagem ao longo da área de estudo, uma chave de interpretação baseada nas imagens de satélite (Sentinel-2) e nas imagens aéreas foi gerada para definição do indicativo de degradação para cada uma das amostras utilizadas.

Foram adotados quatro níveis com base nos dados obtidos em campo: Ausente, Leve, Moderada e Severa. Para o nível Ausente, são considerados *pixels* que não apresentam indicativos de degradação; o nível Leve, *pixels* que apresentam leves indícios de degradação (i.e., densidade menor de forrageiras); o nível Moderado, *pixels* que apresentam, além de uma menor densidade de forrageiras, coloração mesclada à coloração do solo; e o nível Severo, que está associado à *pixels* que são formados por uma maior contribuição do solo, possuindo coloração mais próxima a resposta do solo associada a uma baixa densidade de forrageiras. Na Figura 3.9 estão dispostas as classes juntamente com suas descrições quanto a ocorrência nas imagens Sentinel-2 e as produzidas por ARP em campo.

Figura 3.9 - Chave de interpretação para atribuição de indicativos de degradação de pastagens para as amostras utilizadas na validação dos métodos utilizados.



Fonte: Elaborado pelo autor.

Os resultados serão apresentados também de forma a considerar apenas duas classes: Ausente e Degradado. A classe Degradado nas imagens com apenas duas classes corresponde a uma generalização dos 4 níveis estipulados anteriormente. Deste modo é possível aferir a sensibilidade dos conjuntos de dados à indicativos de degradação das pastagens.

4 RESULTADOS E DISCUSSÕES

4.1 Avaliação de filtros de *speckle*

A primeira parte da metodologia empregada é a relação de um filtro redutor de *speckle* a ser aplicado nas imagens que compõem a série temporal de imagens SAR. Para escolha do filtro adequado para esta pesquisa, seis diferentes filtros foram avaliados conforme exposto na Seção 2.4.1. Todos os filtros foram testados com três diferentes janelas de processamento (3x3, 5x5 e 7x7), com exceção do filtro *Refined Lee* devido à sua equação fixar a janela de processamento numa vizinhança 7x7.

Diferentes valores de *NEL* foram computados devido a associação realizada do filtro Gama MAP com o filtro desenvolvido por [Quegan e Yu \(2001\)](#) (QY). Como o parâmetro *NEL* integra a equação do filtro de Gama, a computação valor de *NEL* varia de acordo com a janela de processamento aplicada no filtro QY. O valor de 4,4 foi computado a partir de áreas homogêneas da imagem, sem associação ao filtro QY e, para suas diferentes combinações com o filtro QY, os valores de 9,69, 13,09 e 14,85 foram utilizados. Consideraram-se 30 observações para a composição do filtro QY, que corresponde a um ano de dados (13/03/2019 à 13/03/2020).

Os pesos para a computação do filtro SDNLM são computados a partir do valor p conforme descrito por [Doblas et al. \(2021\)](#). Desta forma, o parâmetro η corresponde a um limiar adicional para a computação do valor p . Foram testados os valores de 0,8, 0,9 e 0,99 para este parâmetro. Adicionalmente foram testados 4 possibilidades de janelamento para a busca (9x9, 11x11, 13x13 e 15x15). Todos estes testes foram conduzidos no ambiente de programação em nuvem *Google Earth Engine* (GEE), por meio da linguagem de programação *Javascript*. Na Tabela 4.1 são apresentados todos os parâmetros avaliados dos filtros.

Tabela 4.1 - Parâmetros testados para os diferentes filtros de *speckle*.

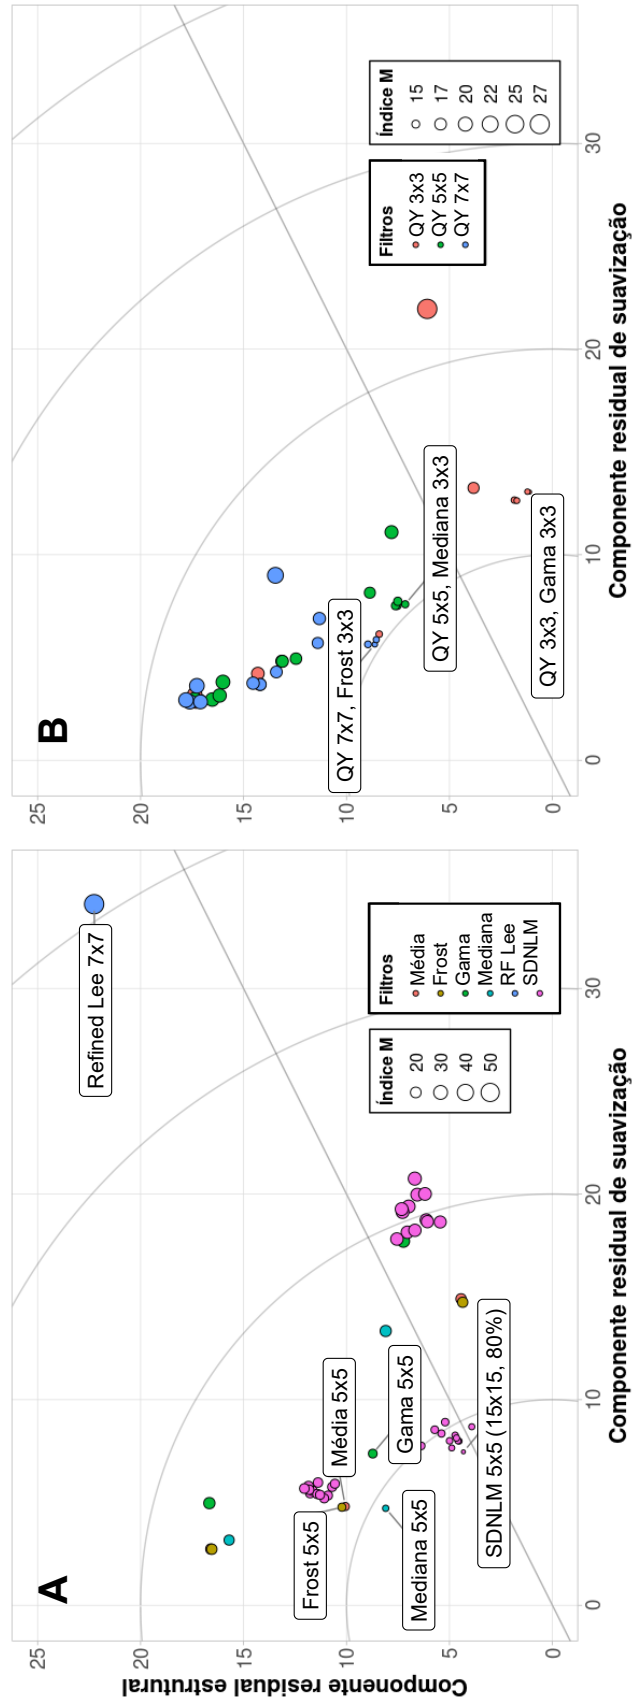
Parâmetros \ Filtros	Média	Mediana	Frost	Gama MAP	SDNLM	Quegan Yu	<i>Refined Lee</i>
Janela de Processamento	3x3	3x3	3x3	3x3	3x3	3x3	
	5x5	5x5	5x5	5x5	5x5	5x5	7x7
	7x7	7x7	7x7	7x7	7x7	7x7	
Janela de Busca					9x9		
					11x11		
					13x13		
					15x15		
<i>NEL</i>				4,4			
				9,69			
				13,09			
				14,85			
η					0,8		
					0,9		
					0,99		
Observações						30	

Fonte: Elaborado pelo autor.

Para a escolha do filtro mais adequado, foi utilizado o índice \mathcal{M} , descrito na seção 2.4.1. Para cada filtro testado, foi construída uma rotina no GEE para que fosse computado, num dado recorte da área de interesse, as métricas que compõem o primeiro termo (que avalia a preservação das estatísticas da imagem filtrada - a partir deste ponto tratada como componente de **suavização**) e o segundo termo (que avalia estruturas remanescentes na imagem razão, utilizando a homogeneidade de Haralick - tratada a partir deste ponto como componente **estrutural**) da equação.

Dado o volume de combinações (total de 91 testes) e com o intuito de facilitar a visualização, os resultados desta análise foram agrupados. Na Figura 4.1, os resultados estão apresentados para os testes considerando os filtros espaciais (A) e a combinação do filtro temporal associado aos espaciais (B), destacando-se apenas os filtros que apresentaram o melhor desempenho (menor valor do índice \mathcal{M}) dos seus respectivos grupos. Os resultados estão representados num plano que demonstram suas posições conforme os valores obtidos em cada uma das componentes.

Figura 4.1 - Valores do índice \mathcal{M} representado nas componentes estrutural e de suavização.



QY representa o filtro proposto por Quegan e Yu (2001).

Fonte: Elaborado pelo autor.

Na Figura 4.2 estão apresentados os resultados derivados da imagem avaliada (original), filtrada e da razão entre elas, para os filtros *Refined Lee* com janela 7x7, Média com janelamento de 5x5 e SDNLM com janela de processamento de 5x5, janela de busca 15x15 e η de 0,8. Observa-se que há uma diminuição de feições estruturais nas imagens razão (destacado pela seta vermelha) associados a um melhor desempenho obtido no índice \mathcal{M} . Na Tabela 4.2 estão dispostos os resultados do cálculo do índice \mathcal{M} e suas componentes para os filtros em destaque na Figura 4.1.


Tabela 4.2 - Valores do índice \mathcal{M} e suas componentes para os filtros destacados. Valores em negrito representam os melhores resultados para cada componente.

Filtros	$0,25 \times r_{ENL,\hat{\mu}}$ (suavização)	$200 \times \delta_h \times 0,75$ (estrutural)	\mathcal{M}
SDNLM (5x5, 15x15, 0,8)	7,46	4,32	11,78
Mediana 5x5	4,72	8,10	12,81
QY _{3x3} Gama 3x3	13,05	1,11	14,15
QY _{7x7} Frost 3x3	5,64	8,62	14,25
QY _{5x5} Mediana 3x3	7,59	7,15	14,74
Média 5x5	4,80	10,05	14,86
Frost 5x5	4,77	10,22	14,99
Gama 5x5	7,38	8,72	16,10
<i>Refined Lee</i> 7x7	34,10	22,25	56,35

Fonte: Elaborado pelo autor.

Dentre os filtros que obtiveram os melhores resultados, destaca-se a combinação do filtro QY associado ao filtro Gama MAP, ambos com janela de processamento de tamanho 3x3 *pixels*, dada a maior preservação dos elementos estruturais na imagem filtrada, ou seja, menor valor na segunda componente (estrutural). Apesar de ser considerado um filtro simples, o filtro da Mediana com janelamento de 5x5 *pixels* obteve o segundo melhor desempenho considerando o valor do índice \mathcal{M} e o melhor desempenho, quando considerada apenas a componente de preservação das propriedades estatísticas da imagem, ou seja, menor valor na primeira componente (suavização). Já o filtro SDNLM com uma janela de processamento de 5x5 *pixels*, com uma janela de busca 15x15 *pixels* e η com valor de 0,8 obteve o melhor (menor) índice \mathcal{M} , em decorrência do valor equilibrado nas componentes de suavização e estrutura.

Figura 4.2 - Imagem original e imagens filtradas associadas à imagem razão. A seta vermelha destaca as feições remanescentes na imagem razão.



Fonte: Elaborado pelo autor.

O resultado do índice \mathcal{M} , nos dois filtros que obtiveram os melhores desempenhos, abre espaço para uma discussão acerca da complexidade e custo computacional associado na produção de séries temporais filtradas. Entretanto, devido ao maior ganho na componente estrutural e o melhor desempenho no índice \mathcal{M} , nesta pesquisa será utilizado o filtro SDNLM nas configurações supracitadas. Isto é, todas as imagens SAR utilizadas para a composição das séries temporais foram filtradas pelo filtro SDNLM com janela de processamento de 5×5 *pixels*, com uma janela de busca 15×15 *pixels* e η com valor de 0,8; e a extração de métricas temporais é realizada a partir das imagens filtradas.

A priorização pela componente estrutural ($\omega = 0,25$) parte da hipótese de que parte da diferença entre os alvos de pastagem herbácea e arbustiva ocorre justamente na estrutura interna da pastagem. Desta forma, uma perda de detalhes na estrutura das feições pode ocasionar uma perda no poder de discriminação das classes (no caso de uma suavização excessiva dos dados).

4.2 Análise exploratória e seleção de dados

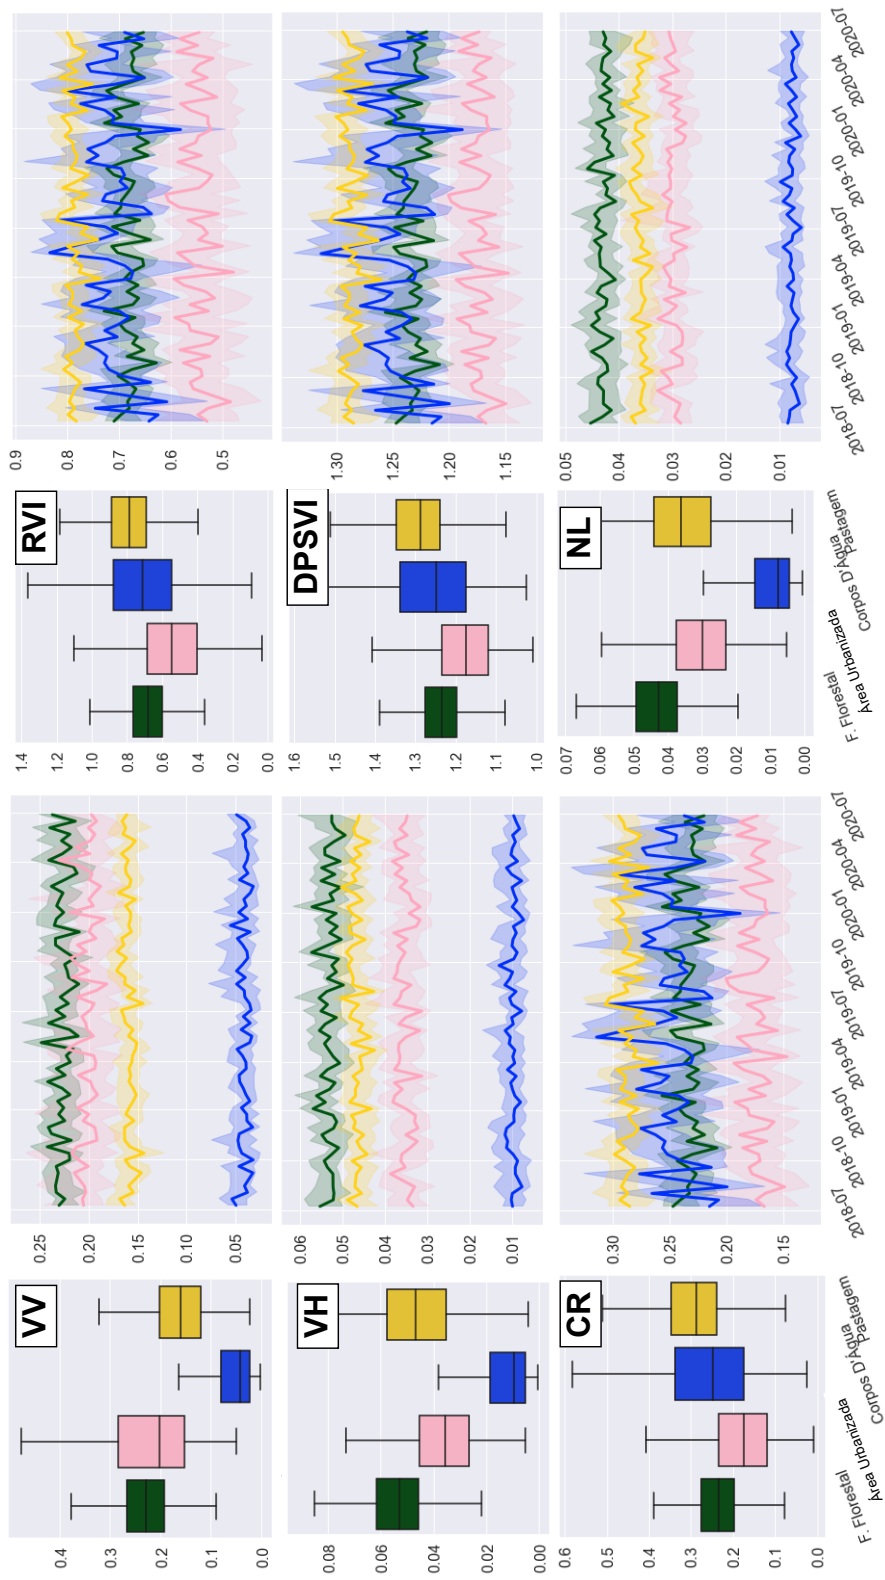
4.2.1 Dados SAR

Na Figura 4.3 são ilustrados gráficos do tipo *boxplot* a fim de se conhecer a dispersão básica dos dados SAR nos seus 6 canais (VV, VH, CR, RVI, DPSVI e NL). Adicionalmente, na mesma figura, são apresentadas séries temporais formadas a partir da média diária dos valores das amostras (e o intervalo de credibilidade de 90% deste valor representado na área sombreada) de cada classe uso e cobertura da terra de interesse neste estudo (Formação Florestal, Área Urbanizada, Corpos D'Água e Pastagem) para todos os canais.

Para construção de ambos os gráficos, foram utilizados os dados filtrados. Os dados coletados são referentes às amostras obtidas na campanha de campo somadas às amostras obtidas por meio da combinação dos mapas de uso e cobertura do solo utilizados. Um total de 250 pontos (50 para cada classe, com exceção da classe Pastagem, que conta com 100 pontos) foram utilizados nesta análise que, ao adicionar a componente temporal, resultam num conjunto de 250 pontos \times 60 imagens ao longo do tempo. Ou seja, um total de 15000 amostras para os dados SAR.

Ao observar o comportamento da classe Corpos D'Água, nota-se que estes apresentam valores consideravelmente baixos, sobretudo nos dados em γ^0 nas polarizações VV, VH e no índice NL. Isso se deve ao fato de que, dada a geometria de

Figura 4.3 - Gráficos de dispersão e de série temporal dos canais SAR, para as classes de interesse (Etapa 1).



Fonte: Elaborado pelo autor.

imageamento do radar e do comprimento de onda das micro-ondas, a interação da energia emitida pelo radar com os corpos hídricos é mínima, podendo ser considerada como áreas de ausência de informação, neste caso. Ao se considerar os índices extraídos a partir destas polarizações (com exceção do NL), os valores equiparam-se para as demais classes dificultando a priori uma boa diferenciação.

As classes Área Urbanizada e Formação Florestal, na polarização VV, apresentam valores próximos, acarretando numa confusão entre as classes ao longo do tempo. Contudo, devido à maior amplitude de variação presentes na classe Área Urbanizada, espera-se que atributos como a amplitude, desvio-padrão e/ou coeficiente de variação sejam importantes na discriminação destes alvos, por representar a variabilidade dos dados.

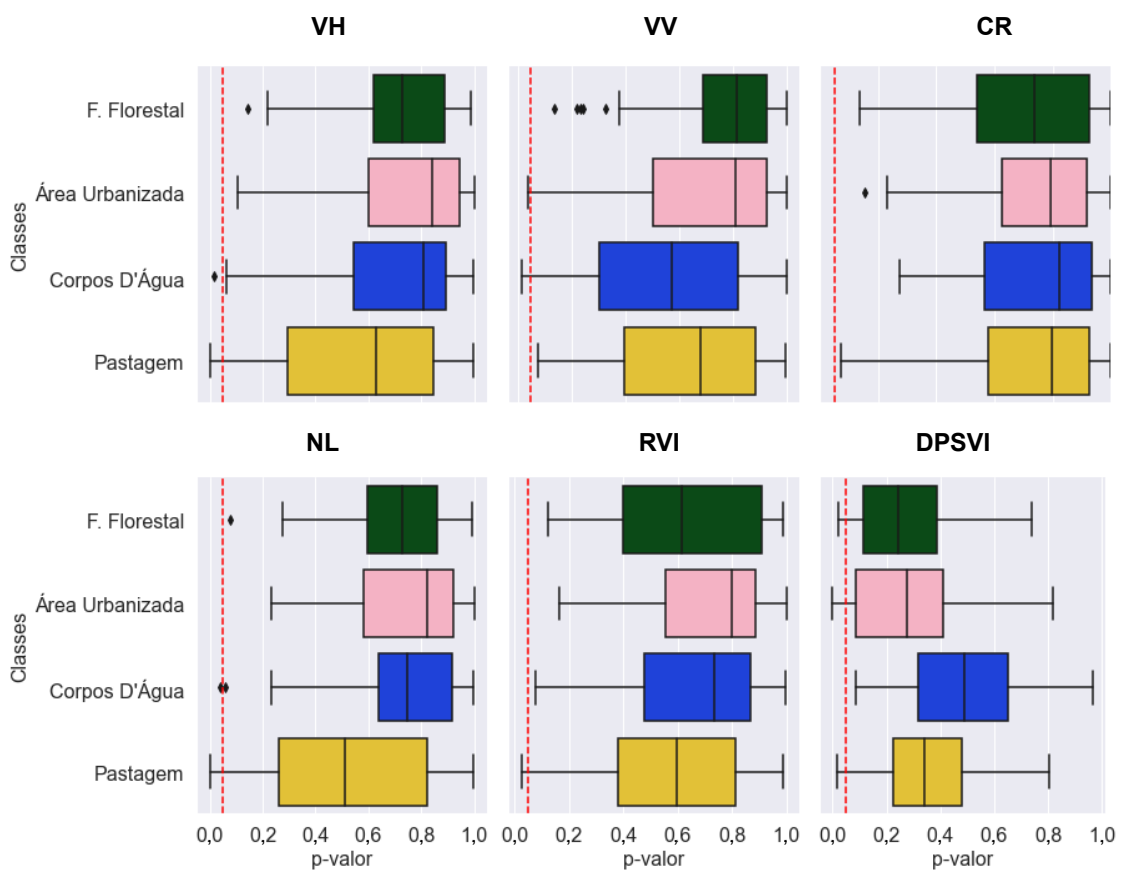
Na polarização cruzada, são registradas com maior intensidade interações do tipo volumétrica, visto que são emitidas pelo sensor ondas na polarização vertical e registradas apenas ondas que retornaram na polarização horizontal. Desta forma, nota-se um aumento na magnitude do sinal das classes Formação Florestal e Pastagem na polarização VH, com relação a classe Área Urbanizada.

É possível observar uma semelhança no comportamento temporal dos alvos nos índices derivados a partir das polarizações (com exceção do NL), porém observa-se que as magnitudes são diferentes, o que pode indicar uma possível correlação entre os atributos que serão derivados destes índices. Nos índices RVI, DPSVI e CR é possível perceber que há grande confusão da classe Corpos D'Água para com as demais, dado que seu valor de intensidade é muito baixo em ambas as polarizações e, por esta razão, espera-se que os atributos derivados destes índices não sejam tão assertivos na separação destas classes. Entretanto ao observar o restante das classes, pode-se perceber que existe pouca confusão ao analisar as observações no tempo. Fato indicativo do diferente comportamento dos valores ao longo do tempo.

De forma análoga, é possível observar uma semelhança do índice NL em relação a polarização VH. No entanto, ao observar as classes Pastagem e Formação Florestal, nota-se a contribuição da polarização VV no aumento das distâncias entre elas ao longo do tempo. Destaca-se que este índice foi o único (entre os testados) que não confundiu a classe Corpos D'Água com as demais.

A fim de verificar se os dados SAR, nesta configuração (filtrados) aderem a distribuição Gama, visando estimar os parâmetros de forma (κ) e escala (θ), para cada série temporal (construindo uma imagem sintética de cada parâmetro), os dados foram testados por meio do teste de Kolmogorov-Smirnov (KS). É possível notar que com base nos resultados desta análise (Figura 4.4) que a grande maioria dos dados mostraram aderência à distribuição com 5% de significância.

Figura 4.4 - Valor p do teste KS relativo ao ajuste das amostras pertinentes à Etapa 1 a uma distribuição Gama nos canais do conjunto de dados SAR.



A linha tracejada vermelha corresponde ao valor de 0,05.

Fonte: Elaborado pelo autor.

Após a computação das métricas, um total de 150 atributos derivados das séries temporais de dados SAR foram obtidos. Na etapa de seleção dos atributos a serem utilizados na classificação da Etapa 1, foi computada a distância JM média por atributo. Em seguida, foi retido apenas um conjunto de 18 atributos com a maior JM média e descorrelacionados entre si (considerando um coeficiente de correlação menor que 0,60). Na Tabela 4.3 estão dispostos os atributos selecionados.


Tabela 4.3 - Métricas SAR selecionadas para a Etapa 1, ordenadas segundo o valor de JM .

Etapa 1					
1	VV Área-Q1	7	VH prange	13	VH Excentricidade
2	VH p25	8	VV prange	14	CR prange
3	RVI κ	9	VV Excentricidade	15	CR Excentricidade
4	DPSVI κ	10	RVI Raio de giro	16	VV Ângulo
5	CR Máximo	11	DPSVI Excentricidade	17	NL Ângulo
6	NL Desvio-padrão	12	RVI Balanço polar	18	CR Ângulo

Fonte: Elaborado pelo autor.

Na Figura 4.5 é possível visualizar uma composição colorida com os três primeiros atributos elencados pela análise. Notam-se que *pixels* pertencentes à classe Área Urbanizada se destacam na cor vermelha, o que indica um destaque dos valores da métrica polar referente a área do primeiro quadrante da série temporal, para a polarização VV, na discriminação desta classe. Para os *pixels* de Pastagem, os valores referentes à métrica de forma da distribuição Gama para o índice RVI foram destacados (na cor azul). Por fim, áreas pertencentes à classe Formação Florestal foram destacadas num misto de valores pertinentes ao 25° percentil da série temporal da polarização VH e da métrica polar anteriormente citada.

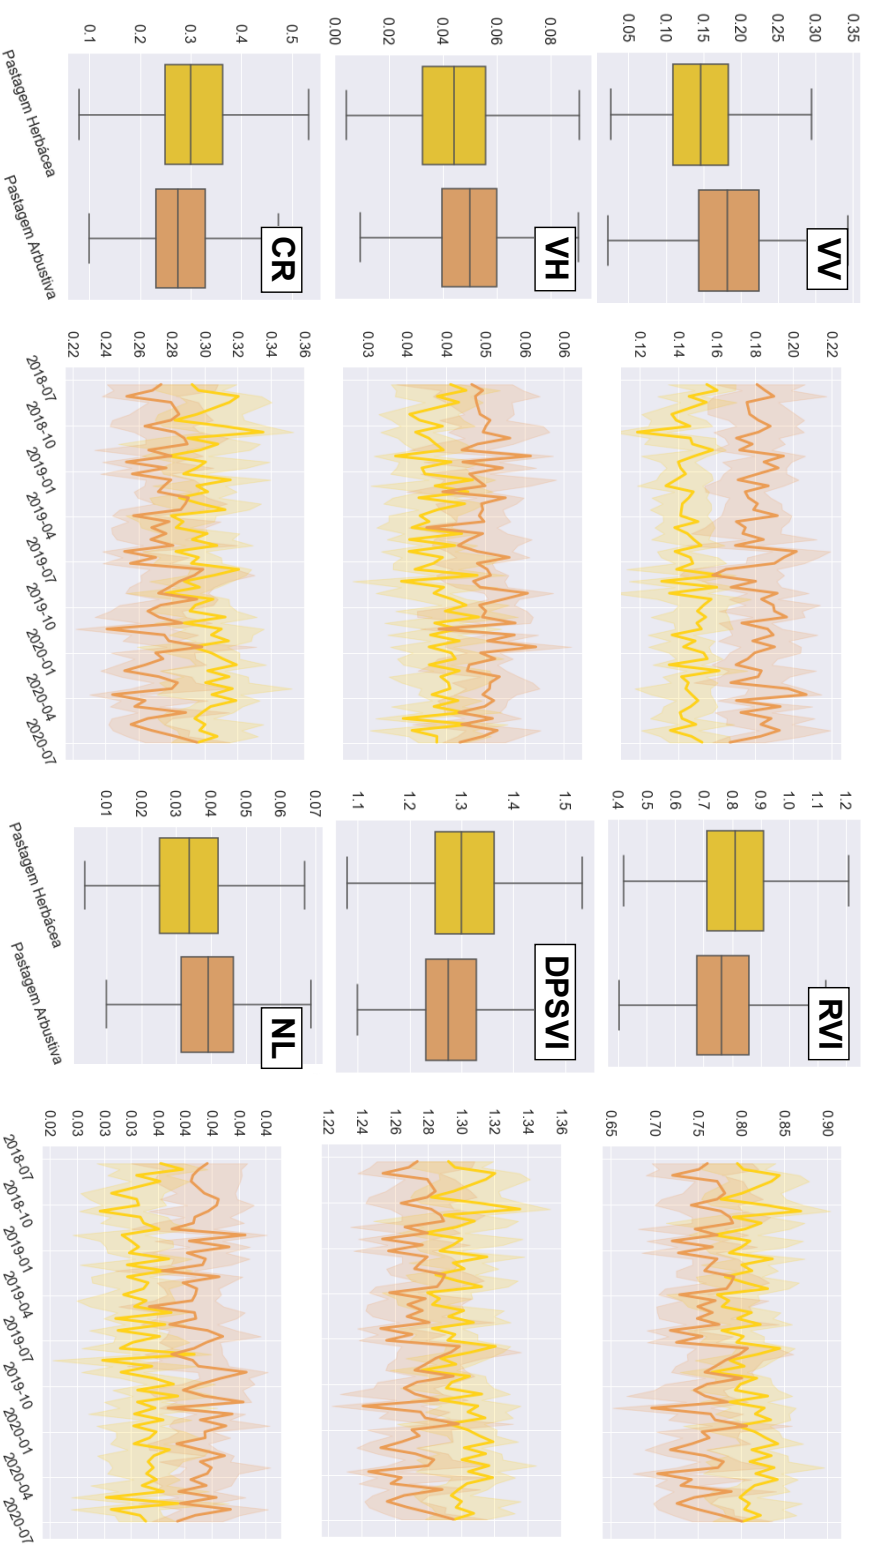
Figura 4.5 - Composição colorida com os três atributos SAR que obtiveram maior JM para a Etapa 1.



Fonte: Elaborado pelo autor.

De maneira similar, após estratificar as amostras da classe Pastagem, subdividindo-as em Pastagem Arbustiva e Herbácea, na Figura 4.6 são ilustrados gráficos do tipo *boxplot* com o objetivo de se conhecer a dispersão dos dados. Nesta figura, também são exibidas as séries temporais da média dos valores das classes por dia e o intervalo de credibilidade de 90% (área sombreada) destes mesmos valores ao longo do tempo.

Figura 4.6 - Gráficos de dispersão e de série temporal dos canais SAR, para as classes de interesse (Etapa 2).



Fonte: Elaborado pelo autor.


É possível notar que, na polarização VV, a classe Pastagem Arbustiva possui um sinal mais elevado ao longo do tempo. Dadas as principais diferenças entre as classes (presença de arbustos) pode-se associar que para a Pastagem Arbustiva, a polarização VV obtém um retorno mais elevado, uma vez que possuem elementos que interagem verticalmente com a energia emitida pelo sensor.

De forma análoga, os maiores valores de retroespalhamento para a polarização cruzada (VH) são obtidos para as Pastagens Arbustivas também. Isto remete a uma maior despolarização da onda vertical ao interagir com os alvos. Desta forma, seja na polarização VV ou VH, conclui-se que a classe Pastagem Arbustiva apresenta um coeficiente de retroespalhamento mais elevado, uma vez que seus elementos constituintes sensibilizam a onda mais fortemente por apresentar elementos compatíveis com o comprimento de onda (em média de 5 *cm*).

Ao avaliar os gráficos de dispersão relativos aos índices, nota-se que nestes canais as classes apresentaram valores de mediana muito próximos, o que indica que este atributo possivelmente não apresentará desempenho satisfatório na separação destas classes. Ao observar as séries temporais dos índices RVI, DPSVI e CR é possível visualizar um comportamento muito similar ao longo do ano com a classe Pastagem Arbustiva sempre apresentando um menor valor no sinal (contrário ao resultado obtido nos canais VV e VH). A série temporal do índice NL apresenta comportamento similar ao obtido no canal VV, mantendo uma média dos valores da classe Pastagem Arbustiva acima da Pastagem Herbácea.

Ao analisar os índices, nota-se que as Pastagens Herbáceas apresentam grandes variações entre as observações (i.e entre as datas). Em consonância, dados de radar, devido a faixa de comprimento de onda em que operam, são muito susceptíveis a mudanças no conteúdo hídrico dos alvos (DOBLAS et al., 2020; WOODHOUSE, 2006). Portanto, uma análise do desvio com relação à média dos valores dos canais ao longo do tempo foi realizada para as classes Pastagem Herbácea e Arbustiva, utilizando como referência as amostras utilizadas na Figura 3.4. Para compor os dados de precipitação, foram utilizados dados do *Climate Hazards Group InfraRed Precipitation with Station Data* (CHIRPS) (FUNK et al., 2015) para obtenção de uma média móvel da precipitação na área de estudo, considerando uma janela de 60 dias precedentes ao imageamento, e dados do *Integrated Multi-satellitE Retrievals for Global Precipitation Measurement* (IMERG/GPM) (HUFFMAN et al., 2015) para obtenção da precipitação acumulada nas últimas 12 h precedentes ao imageamento (Figura 4.7).

Figura 4.7 - Desvio do valor do retorno do sinal dos canais SAR com relação à média do valor de todo o período analisado, para as classes Pastagem Arbustiva e Herbácea associadas a dados de precipitação. As linhas tracejadas verticais cinza e vermelho sinalizam, respectivamente, observações do início e final do período chuvoso (20 de abril de 2019 à 01 de novembro de 2019).



onde "MPrecip 60d" corresponde à média móvel da precipitação considerando uma janela de 60 dias precedentes ao imageamento (CHIRPS); E "SPrecip 12h" à precipitação acumulada nas últimas 12h precedentes ao imageamento (IMERG/GPM).

Fonte: Elaborado pelo autor.

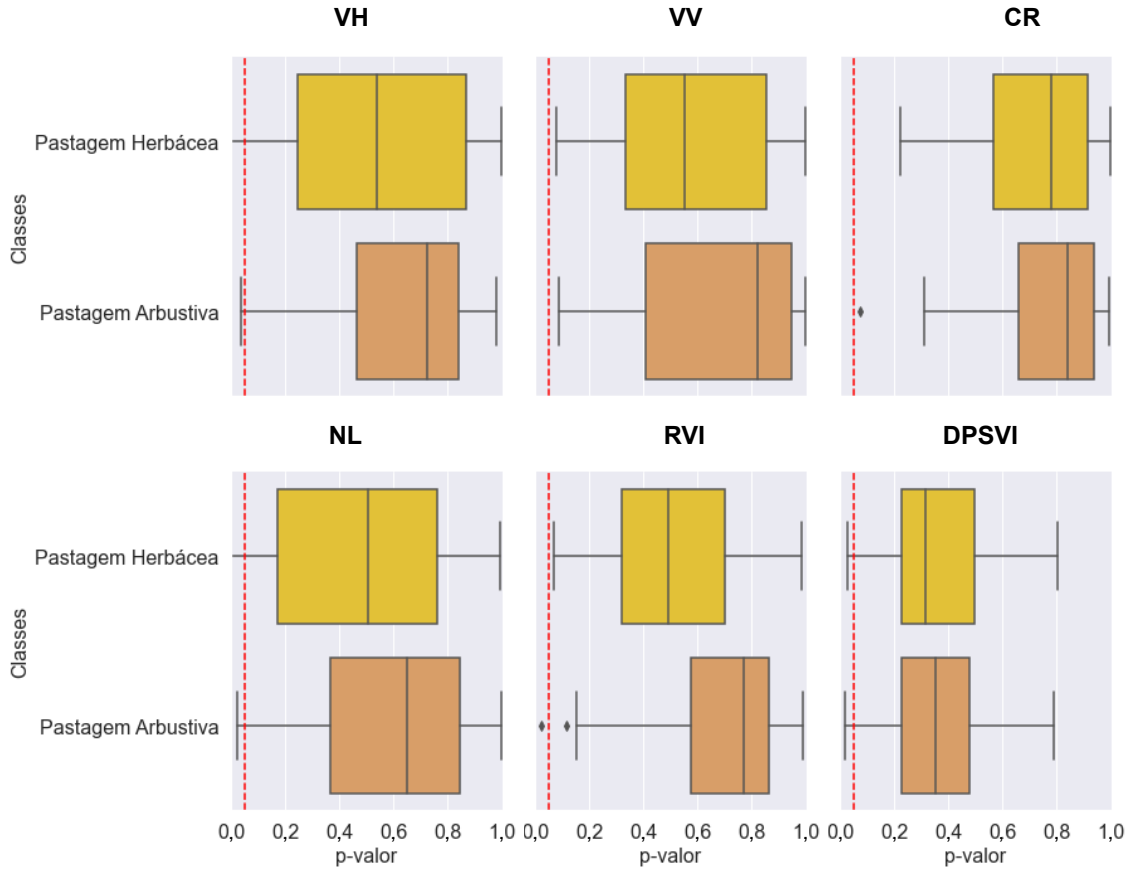
Ao analisar os desvios do retorno do sinal ao longo do tempo, nota-se que os maiores desvios ocorrem, com uma maior frequência, na classe de Pastagem Herbácea que se apresenta mais sensível para chuvas acumuladas se comparado aos desvios obtidos pela Pastagem Arbustiva. Esses fatores podem estar relacionados com a predominância de vegetação rasteira que pode ser mais sensível a uma mudança abrupta da umidade.

Em contraponto, a variação do retorno do sinal dos canais relacionados à classe Pastagem Arbustiva parece estar mais associada à variação da média móvel de chuvas do período, quando comparada à Pastagem Herbácea. Tais fatores podem estar relacionados com a presença de arbustos e esta vegetação ser menos sensível a mudança abrupta de umidade. No entanto, nota-se determinada sensibilidade da Pastagem Arbustiva também a essas mudanças abruptas sobretudo na polarização VV.

Deste modo, é esperado que na ocorrência de fortes chuvas (pontuais) as diferenças existentes entre as pastagens tornem-se mais evidentes, uma vez que estas reagem de forma diferente a mudança abrupta de umidade enquanto que, no período chuvoso, mesmo que ainda seja possível diferenciá-las, torna-se mais desafiador dado que os valores de retroespalhamento aproximam-se ao longo do tempo na presença constante de chuvas.

Similarmente aos testes executados nos dados SAR para a Etapa 1, as amostras estratificadas para as classes Pastagem Arbustiva e Herbácea foram submetidas ao teste KS com o objetivo de avaliar a aderência à distribuição Gama. É possível notar que o resultado se repete, atestando que a grande maioria dos dados mostram aderência a distribuição. Na Figura 4.8 são mostrados os valores p referente ao resultado do teste KS relativo ao ajuste das amostras com 5% de significância.

Figura 4.8 - Valor p do teste KS relativo ao ajuste das amostras pertinentes à Etapa 2 a uma distribuição Gama nos canais do conjunto de dados SAR.



A linha tracejada vermelha corresponde ao valor de 0,05.

Fonte: Elaborado pelo autor.

Após a seleção dos atributos a serem utilizados na classificação da Etapa 2, com a mesma metodologia empregada para a Etapa 1, foi possível reduzir o conjunto de 150 atributos em apenas um conjunto de 30 atributos com a maior JM média e decorrelacionados entre si (considerando um coeficiente de correlação menor que 0,60). Na Tabela 4.4 estão dispostos os atributos selecionados.


Tabela 4.4 - Métricas SAR selecionadas para a Etapa 2, ordenadas segundo o valor de JM .

Etapa 2					
1	VV Mínimo	11	VH Área-Q1	21	VH Excentricidade
2	VH Desvio-padrão	12	VV Balanço polar	22	VV Ângulo
3	CR κ	13	RVI θ	23	VH prange
4	VH CSI	14	VV Raio de giro	24	DPSVI CSI
5	NL Área-Q2	15	VV Excentricidade	25	CR Ângulo
6	RVI prange	16	VV prange	26	VH Ângulo
7	CR Área-Q4	17	NL Máximo	27	VH Raio de giro
8	VH Balanço polar	18	CR Raio de giro	28	VV Range
9	RVI Range	19	CR Excentricidade	29	RVI CSI
10	VV CSI	20	RVI Balanço polar	30	DPSVI Excentricidade

Fonte: Elaborado pelo autor.

Análogo ao executado na Etapa 1, na Figura 4.9 é possível visualizar uma composição colorida com os três primeiros atributos elencados pela análise. Nesta composição foram utilizadas as métricas correspondentes ao valor mínimo (não-nulo) da série temporal na polarização VV (no canal vermelho), o desvio padrão dos valores da série temporal na polarização VH (no canal verde) e o parâmetro de forma dos valores ajustados à distribuição Gama da série temporal da razão entre a polarização VH e VV (no canal azul). Desta forma, as diferentes pastagens foram evidenciadas em tons de verde ao azul, o que indica uma prevalência dos valores, sobretudo dos desvios obtidos na polarização VH, associados com o parâmetro de forma de CR.

Figura 4.9 - Composição colorida com os três atributos SAR que obtiveram maior JM para a Etapa 2.



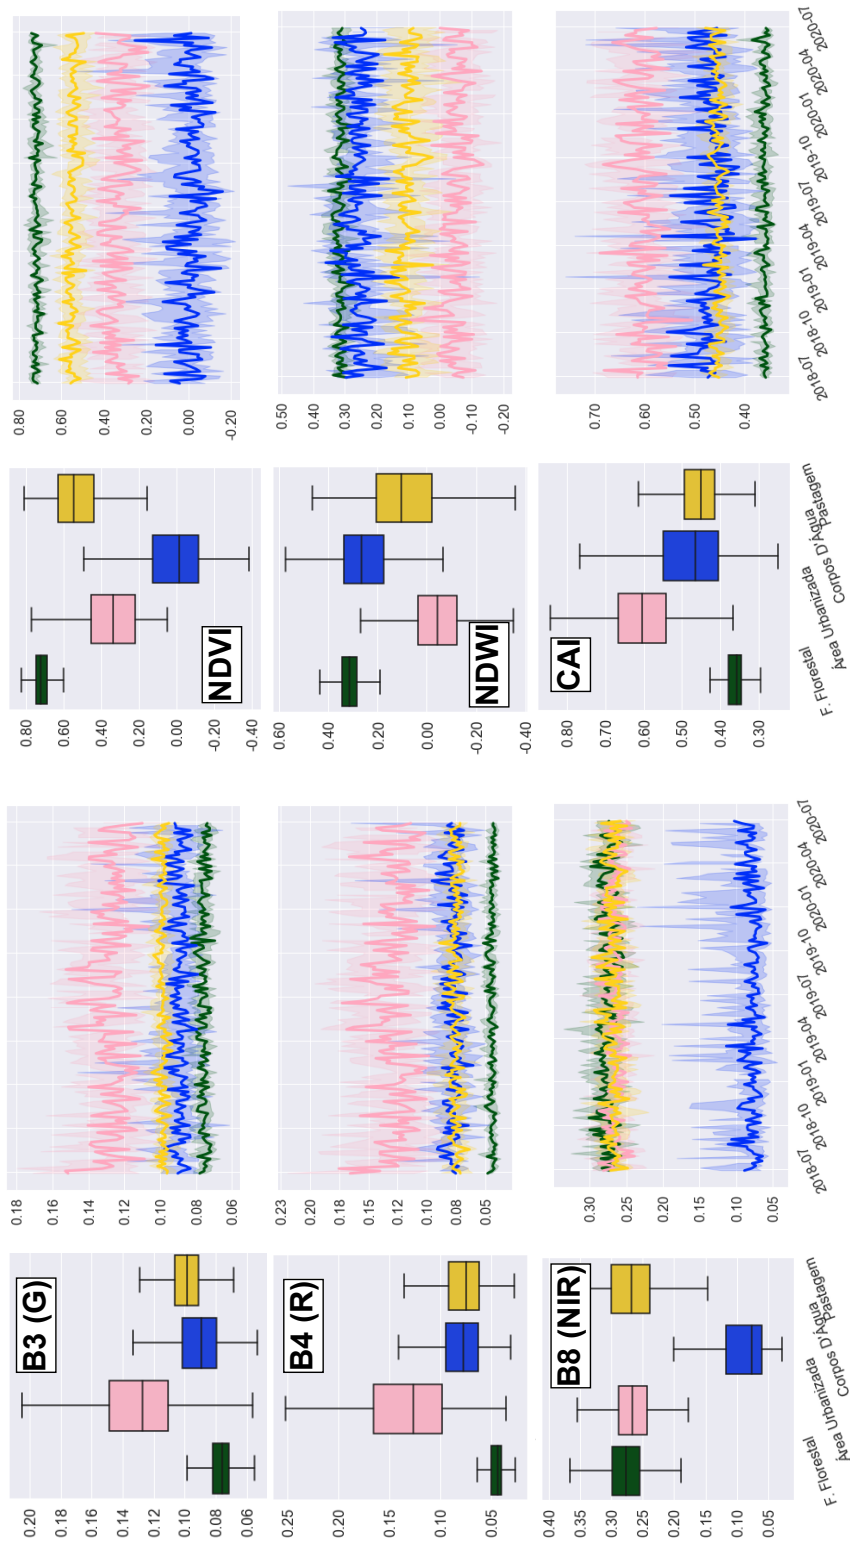
Fonte: Elaborado pelo autor.

4.2.2 Dados ópticos

Para os dados ópticos, em virtude do número de bandas e índices, nesta Seção optou-se por mostrar apenas os canais do verde, vermelho, infravermelho próximo e os índices NDVI, NDWI e CAI. Portanto, de forma equivalente ao executado para os dados SAR, na Figura 4.10 estão ilustrados os gráficos do tipo *boxplot* e as séries temporais formadas a partir da média diária dos valores das amostras (e o intervalo de credibilidade de 90% deste valor representado na área sombreada) de cada classe uso e cobertura da terra de interesse neste estudo para os canais já citados.

Em relação a construção dos gráficos, os dados utilizados são referentes às mesmas amostras utilizadas para o conjunto de dados SAR. Já com a máscara de nuvens aplicada, um conjunto de 250 pontos \times 145 aquisições ao longo do tempo foram utilizados para compor o espaço amostral, totalizando 36250 amostras para os dados ópticos.

Figura 4.10 - Gráficos de dispersão e de série temporal dos canais de interesse, para as classes de interesse (Etapa 1).



Fonte: Elaborado pelo autor.

Ao avaliar o conjunto de dados ópticos por meio dos gráficos *boxplot*, diferentes padrões de dispersão dos dados são observados sobretudo nos índices, uma vez que são obtidos por meio de operações entre diferentes bandas do espectro eletromagnético. Ao avaliar o comportamento temporal da classe Corpos D'Água, nota-se que os dados ao longo do tempo apresentam alta variabilidade, sobretudo (excessivamente) para o índice CAI. Tal fato pode estar associado a presença de bancos de areia em períodos de seca dos cursos d'água, além da presença de sólidos em suspensão e/ou vegetação. Para o índice CAI, isso se deve ao fato de que as bandas utilizadas na razão são comprimentos de onda nas quais a água pouco reflete (faixa do infravermelho de ondas curtas), por esta razão, entende-se que o comportamento da classe Corpos D'Água neste índice não tráz informação significativa.

Para os canais do verde e do vermelho, a média dos valores das classes Corpos D'Água e Pastagem apresentam valores aproximados. No entanto, para discriminação da classe Área Urbanizada a média dos valores apresenta valores bem distintos, o que pode indicar boa separabilidade por esta métrica. Com relação ao canal do infravermelho-próximo, as classes apresentam valores muito próximos e passíveis de confusão ao longo do tempo, com exceção da classe de Corpos D'Água

Nos três índices em geral, uma boa discriminação pode ser esperada entre as classes Pastagem, Área Urbanizada e Formação Florestal. Essa característica é refletida tanto nos gráficos de dispersão (*boxplots*) quanto nas séries temporais. Para diferenciação de Corpos D'Água com relação as demais classes, o índice NDVI em conjunto com o NDWI apresentam boa discriminação ao longo do tempo. Baseado em tais dados e seus comportamentos ao longo do tempo, não são esperadas grandes dificuldades para se obter uma classificação satisfatória com o emprego de métricas derivadas das séries temporais.

Um total de 276 atributos derivados das séries temporais de dados ópticos foram gerados na etapa de computação das métricas temporais. Após a etapa de seleção dos atributos para a classificação da Etapa 1, restaram-se apenas 29 atributos com a maior *JM* média e descorrelacionados entre si (considerando um coeficiente de correlação menor que 0,6), dispostos na Tabela 4.5.


Tabela 4.5 - Métricas ópticas selecionadas para a Etapa 1, ordenadas segundo o valor de *JM*.

Etapa 1					
1	B12 p10	11	NDVI Excentricidade	21	B4 Excentricidade
2	NDVI Média	12	NDWI CSI	22	CAI Ângulo
3	B3 Máximo	13	NDWI Range	23	CAI Excentricidade
4	NDVI Coef. variação	14	B6 Máximo	24	B12 Ângulo
5	B4 Área-Q4	15	B6 Área-Q2	25	B4 Ângulo
6	NDWI Somatório	16	B11 Excentricidade	26	NDVI Ângulo
7	B12 Coef. variação	17	NDWI Balanço polar	27	B8A Ângulo
8	B11 prange	18	B8A Excentricidade	28	NDWI Ângulo
9	NDWI Coef. variação	19	NDWI Excentricidade	29	B3 Ângulo
10	B11 Somatório	20	B6 Balanço polar		

Fonte: Elaborado pelo autor.

Na Figura 4.11 é possível visualizar uma composição colorida com os três primeiros atributos elencados pela análise. Nota-se que *pixels* representativos de feições antrópicas (Área Urbanizada e Pastagem) se destacam em diferentes tons de magenta e lilás. Fato que indica uma prevalência dos valores referentes ao 10° percentil da série temporal da banda 12 (infravermelho de ondas curtas) e aos valores máximos obtidos pela série temporal da banda 3 (verde). Já a classe Formação Florestal destaca-se em tons de verde pertinentes ao valor da média da série temporal de NDVI.

Figura 4.11 - Composição colorida com os três atributos ópticos que obtiveram maior JM média para a Etapa 1.

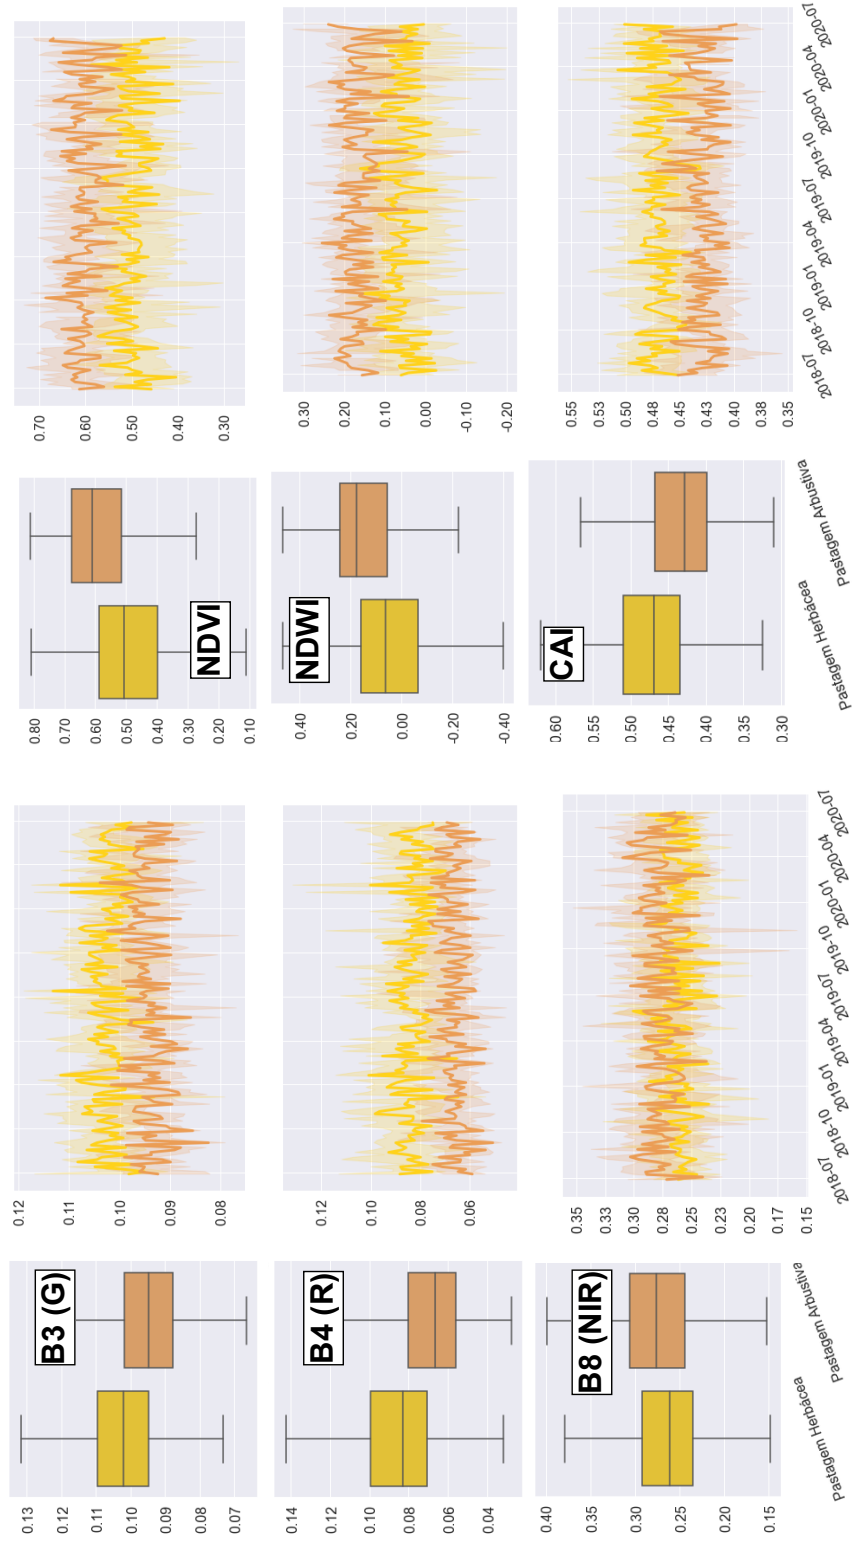


Fonte: Elaborado pelo autor.

Na Figura 4.12 estão dispostas as dispersões dos dados para as classes Pastagem Herbácea e Pastagem Arbustiva. Adicionalmente, na mesma figura, são apresentadas séries temporais formadas a partir da média diária dos valores das amostras (e o intervalo de credibilidade de 90% deste valor representado na área sombreada). Ao observar os valores de NDVI para as diferentes pastagens, nota-se que os valores para a classe Pastagem Arbustiva apresentam valores mais elevados.

Uma vez que o NDVI realça características relacionadas ao vigor vegetativo/biomassa da vegetação (ROUSE et al., 1974), o comportamento retratado na dispersão dos dados para este índice pode estar relacionado ao fato das Pastagens Arbustivas apresentarem maior ocorrência de elementos arbustivos, o que aumenta o teor de biomassa da vegetação e, por consequência, valores maiores no NDVI.

Figura 4.12 - Gráficos de dispersão e de série temporal dos canais de interesse, para as classes de interesse (Etapa 2).

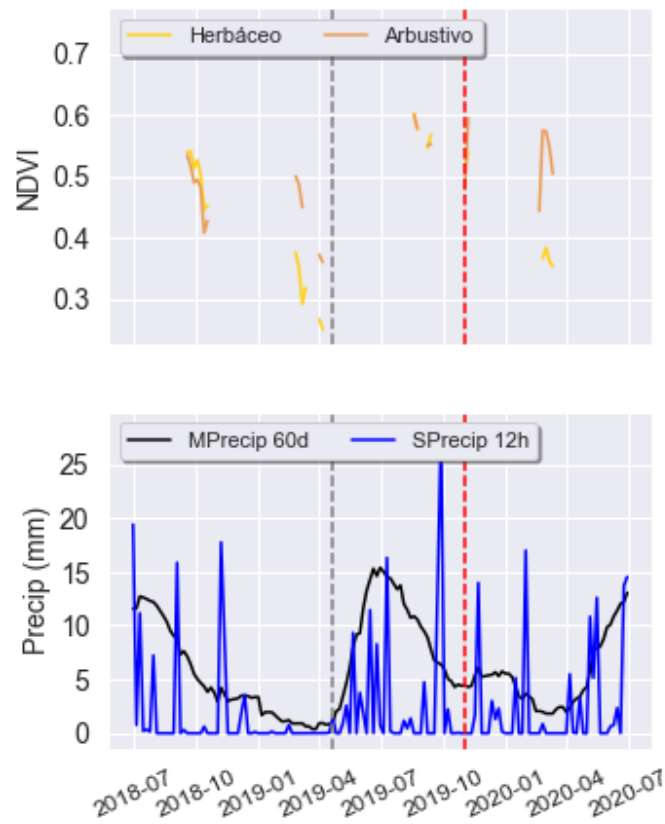


Fonte: Elaborado pelo autor.

É possível observar que, baseado na avaliação da dispersão dos dados, que as classes apresentam valores muito parecidos em todos os canais. No entanto, para os índices, as diferenças nos valores tornam-se mais evidentes. Para o índice NDWI a condição é similar ao visualizado no índice NDVI. Este comportamento pode estar associado a maior capacidade da vegetação arbustiva em reter a umidade, se comparada a vegetação herbácea. Já para o índice CAI, o contrário é observado, de modo que os valores registrados para a classe Pastagem Herbácea apresenta valores maiores, o que pode indicar uma maior presença de celulose (NAGLER et al., 2003).

Um aspecto a ser mencionado é acerca da disponibilidade de dados ópticos válidos para a análise de uso e cobertura da terra, sobretudo na região amazônica. Sabe-se que as nuvens atuam como um fator limitante para a aquisição de dados com sensores ópticos para estes casos, como já mencionado nas seções anteriores. Desta forma, na Figura 4.13 é demonstrada uma série temporal do NDVI evidenciando o impacto da ocorrência de nuvens ao longo do tempo na construção de séries temporais. Adicionalmente, estão dispostas séries temporais de precipitação média ao longo do tempo (janela de 60 dias precedentes ao imageamento do dado óptico) e de precipitação acumulada (janela de 12h precedentes ao imageamento do dado óptico), com destaque para época chuvosa (linhas pontilhadas verticais). As amostras utilizadas para compor as séries foram obtidas, pontualmente, ao centro dos mesmos exemplos utilizados na ilustração referente à chave de interpretação (Figura 3.4) e na análise do impacto da precipitação nos dados SAR.

Figura 4.13 - Consequência da ocorrência frequente de nuvens na construção de séries temporais com dados ópticos.



onde "MPrecip 60d" corresponde à média móvel da precipitação considerando uma janela de 60 dias precedentes ao imageamento (CHIRPS); E "SPrecip 12h" à precipitação acumulada nas últimas 12h precedentes ao imageamento (IMERG/GPM).

Fonte: Elaborado pelo autor.

É possível observar, com a ausência de informação na série temporal (devido ao mascaramento das nuvens), o impacto na região com cobertura frequente de nuvens, sobretudo na estação chuvosa. Esta característica reforça a necessidade do emprego de sensores de radar na discriminação das pastagens. Contudo, ainda assim é possível extrair as métricas descritas na Seção 2.4.3 mesmo que com um menor número de observações válidas.

Cabe salientar que a frequência de observações utilizada para a computação dos níveis de precipitação, entre o gráficos utilizados para os dados SAR e ópticos, são diferentes dada a frequência de revisita de cada sensor. Desta forma, a precipitação computada para as observações ópticas contém um número maior de observações.

Devido à escassez de observações ópticas válidas (considerando uma única amostra ao longo do tempo), a análise do impacto da precipitação na variação do sinal é inconclusiva. Portanto, optou-se por considerar a média das observações válidas para cada data, o que possibilita a construção de uma série temporal da média diária dos valores das classes. Portanto, foi computado o desvio desta média das amostras por dia com relação à média de todo o período analisado. Para preencher os dias nos quais não houve nenhuma aquisição válida na área de estudo, utilizou-se o valor da primeira observação válida precedente (*forward filling*). Pode-se observar, na Figura 4.14, que os maiores desvios são obtidos na ocorrência de chuvas acumuladas nas 12 horas precedentes ao imageamento.


Desvios maiores podem ser observados para a classe Pastagem Herbácea quanto à ocorrência de chuvas nas 12h antes do imageamento, sobretudo nos índices NDWI e CAI. Na época chuvosa, os desvios obtidos pelas classes Pastagem Herbácea e Arbustiva equiparam-se. No entanto, na maior parte do período chuvoso, a Pastagem Herbácea mostrou-se mais sensível, em todos os canais, a ocorrência das chuvas devido aos maiores valores obtidos.

No início do período de análise (metade do período chuvoso para o ano de 2018) é possível observar que a classe Pastagem Arbustiva obteve maiores desvios em todos os canais com exceção do B8 (infravermelho próximo). Adicionalmente, o comportamento sazonal parece mais evidente nos índices se comparados aos demais canais.

Na etapa de computação das métricas temporais, um total de 276 atributos (23 métricas temporais multiplicadas por 12 canais) foram derivados das séries temporais de dados ópticos. E, após a etapa de seleção dos atributos para a classificação da Etapa 2, foram retidos apenas 36 atributos com a maior distância JM média e desconcorrelacionados entre si (considerando um coeficiente de correlação menor que 0,60). Os atributos selecionados estão dispostos na Tabela 4.6.

De forma similar ao executado para os dados SAR nas etapas predecessoras, na Figura 4.15 é possível visualizar uma composição colorida formada pelos três atributos que obtiveram maior JM média desconcorrelacionados entre si (considerando um coeficiente de correlação de 0,6). Nesta composição, uma gama maior de cores pode ser observada para representação dos *pixels* pertencentes às pastagens, o que indica uma maior possibilidade de diferenciação entre as classes. Os valores da média da série temporal do canal B4 (vermelho), área do 4º quadrante da métrica polar do índice CAI e do balanço polar da série temporal da banda 12 (infravermelho de ondas curtas) foram usados na composição colorida nos canais RGB, respectivamente.

Figura 4.14 - Desvio da média diária do retorno do sinal dos canais ópticos com relação à média de todo o período analisado, associado à dados de precipitação para as classes Pastagem Herbácea e Arbustiva.



onde "MPrecip 60d" corresponde à média móvel da precipitação considerando uma janela de 60 dias precedentes ao imageamento (CHIRPS); E "SPrecip 12h" à precipitação acumulada nas últimas 12h precedentes ao imageamento (IMERG/GPM).


Fonte: Elaborado pelo autor.

Tabela 4.6 - Métricas ópticas selecionadas para a Etapa 2, ordenadas segundo o valor de *JM* média.

Etapa 2					
1	B4 Média	11	NDWI Área-Q1	21	B11 Excentricidade
2	CAI Área-Q4	12	CAI Excentricidade	22	B8A Área-Q2
3	B12 Balanço polar	13	NDVI CSI	23	B5 CSI
4	B3 Desvio-padrão	14	NDWI Excentricidade	24	B5 Excentricidade
5	NDVI Máximo	15	CAI Máximo	25	B3 Excentricidade
6	NDVI Raio de giro	16	NDWI Ângulo	26	B8 Balanço polar
7	B12 Mínimo	17	B5 Raio de giro	27	NDVI Excentricidade
8	NDWI CSI	18	NDWI Área-Q4	28	B8A Excentricidade
9	B11 Somatório	19	B8A Mediana	29	NDVI Ângulo
10	NDWI Coef. variação	20	B7 Somatório	30	B5 Ângulo

Fonte: Elaborado pelo autor.

Figura 4.15 - Composição colorida com os três atributos ópticos que obtiveram maior *JM* média para a Etapa 2.



Fonte: Elaborado pelo autor.

4.2.3 Combinação de dados

Igualmente à análise de seleção de variáveis executada para os conjuntos de dados ópticos e de radar, nesta seção foram analisados os dados resultantes da combinação dos atributos extraídos das séries temporais oriundas destes dois conjuntos de dados precedentes. Para tanto, todos os atributos obtidos das séries temporais ópticas e de radar foram empilhados visando novas seleções de variáveis para as Etapas 1 e 2 do processo de classificação. Logo, um total de 426 atributos (150 SAR + 276 ópticos) foram analisados a fim de derivar os atributos com maior JM média e descorrelacionados entre si (considerando um coeficiente de correlação de 0,6).

Para a Etapa 1, após a análise de seleção de variáveis, um total de 45 atributos foram retidos para o processo de classificação. Os atributos selecionados estão apresentados na Tabela 4.7. Na Figura 4.16 é possível visualizar uma composição colorida formada pelos três atributos que obtiveram maior JM média e descorrelacionados entre si.


Tabela 4.7 - Métricas do conjunto de dados combinado selecionadas para a Etapa 1, ordenadas segundo o valor de JM média.

Etapa 1							
1	B12 p10	13	CR κ	25	NDWI Excentricidade	37	B12 Ângulo
2	NDVI Média	14	NDVI Excentricidade	26	B6 Balanço polar	38	B4 Ângulo
3	VV Área-Q1	15	NDWI CSI	27	VV Excentricidade	39	NDVI Ângulo
4	B3 Máximo	16	CR Máximo	28	RVI Raio de giro	40	B8A Ângulo
5	NDVI Coef. variação	17	NL Desvio-padrão	29	DPSVI Excentricidade	41	NDWI Ângulo
6	B4 Área-Q4	18	NDWI range	30	RVI Balanço polar	42	VV Ângulo
7	NDWI Somatório	19	VH prange	31	B4 Excentricidade	43	NL Ângulo
8	RVI κ	20	B6 Máximo	32	VH Excentricidade	44	B3 Ângulo
9	B12 Coef. variação	21	B11 Excentricidade	33	CR prange	45	CR Ângulo
10	B11 prange	22	VV prange	34	CAI Ângulo		
11	NDWI Coef. variação	23	NDWI Balanço polar	35	CAI Excentricidade		
12	B11 Somatório	24	B8A Excentricidade	36	CR Excentricidade		

Fonte: Elaborado pelo autor.

Os *pixels* pertencentes à classe Pastagem foram evidenciados na coloração vermelha, o que indica prevalência dos valores do 10º percentil das séries temporais da banda 12 (infravermelho de ondas curtas) assim como para o conjunto de dados ópticos. *Pixels* representativos da classe Formação Florestal foram evidenciados pela média da série temporal de NDVI e os *pixels* relativos à classe Área Urbanizada foram destacados em magenta, o que indica uma maior contribuição dos canais vermelho e azul.

Figura 4.16 - Composição colorida com os três atributos do conjunto de dados combinado que obtiveram maior JM média para a Etapa 1.



Fonte: Elaborado pelo autor.


Para a Etapa 2, após a seleção de variáveis, os 426 atributos foram reduzidos a um conjunto de 64 atributos para serem classificados com o objetivo de separar os tipos de pastagem. Na Tabela 4.8 estão apresentados os atributos escolhidos. Adicionalmente, na Figura 4.17 estão representados os três primeiros atributos que obtiveram maior *JM* média. Nota-se que uma gama maior de cores apresenta-se para a distinção das pastagens, o que indica uma combinação das três componentes elencadas que compõem os canais RGB.

Tabela 4.8 - Métricas do conjunto de dados combinado selecionadas para a Etapa 2, ordenadas segundo o valor de *JM* média.

Etapa 2							
1	B4 Média	17	NDWI Área-Q1	33	VV Raio de giro	49	B8A Excentricidade
2	VH θ	18	CAI Excentricidade	34	VV Excentricidade	50	VH prange
3	CAI Área-Q4	19	NDVI CSI	35	VV prange	51	DPSVI CSI
4	B12 Balanço polar	20	NDWI Excentricidade	36	NL Máximo	52	NDVI Ângulo
5	VH Desvio-padrão	21	CAI Máximo	37	B11 Excentricidade	53	B5 Ângulo
6	B3 Desvio-padrão	22	NDWI Ângulo	38	B8A Área-Q2	54	DPSVI Ângulo
7	DPSVI κ	23	VH Balanço polar	39	CR Raio de giro	55	CAI Ângulo
8	VH CSI	24	B5 Raio de giro	40	CR Excentricidade	56	VH Ângulo
9	NDVI Máximo	25	RVI range	41	B5 CSI	57	VH Raio de giro
10	NDVI Raio de giro	26	VV Máximo	42	B5 Excentricidade	58	B7 Ângulo
11	RVI prange	27	VV CSI	43	RVI Balanço polar	59	B4 Excentricidade
12	B12 Mínimo	28	NDWI Área-Q4	44	B3 Excentricidade	60	B12 Ângulo
13	NDWI CSI	29	B8A Mediana	45	VH Excentricidade	61	B8 Mínimo
14	B11 Somatório	30	B7 Somatório	46	B8 Balanço polar	62	RVI CSI
15	NDWI Coef. variação	31	VV Balanço polar	47	NDVI Excentricidade	63	B4 Ângulo
16	CR Área-Q4	32	RVI θ	48	VV Ângulo	64	DPSVI Excentricidade

Fonte: Elaborado pelo autor.

Figura 4.17 - Composição colorida com os três atributos do conjunto de dados combinado que obtiveram maior *JM* média para a Etapa 1.



Fonte: Elaborado pelo autor.

4.3 Resultados da classificação por *Random Forest*

Baseado nos resultados de análise exploratória e seleção de variáveis, os diferentes cenários passaram pelo modelo de classificação *Random Forest* (BREIMAN, 2001). Conforme explicado no Capítulo 3, do total de 250 pontos utilizados no processo de classificação, dois terços destes compuseram a etapa de treinamento do modelo e um terço a parte de validação dos dados. Para a obtenção de um intervalo de resultados confiáveis, o modelo foi submetido ao treinamento e validação num experimento de Monte Carlo (MC) com 1000 iterações. Desta forma é possível obter a média e os desvios dos indicativos de acurácia global (AG), além de um conjunto de dados para a realização do teste estatístico de McNemar. Adicionalmente, serão apresentadas as imagens de diferença absoluta, cujo objetivo é destacar as áreas onde houve concordância e discordância nas imagens classificadas.

Nas figuras que ilustram os resultados de classificação obtidos ao longo das etapas, estarão dispostos a média e o desvio-padrão da acurácia global obtidos com base nas 1000 iterações executadas pelo experimento Monte Carlo. Adicionalmente, também estarão apresentadas a imagem classificada e a matriz de confusão correspondente à mediana dos valores obtidos pelo experimento. A escolha da mediana dos valores obtidos para retratar a classificação ocorreu com o objetivo de representar, de forma aproximada, o resultado obtido pela média dos valores advindos do experimento Monte Carlo para a acurácia global, sem construir uma "nova classificação".

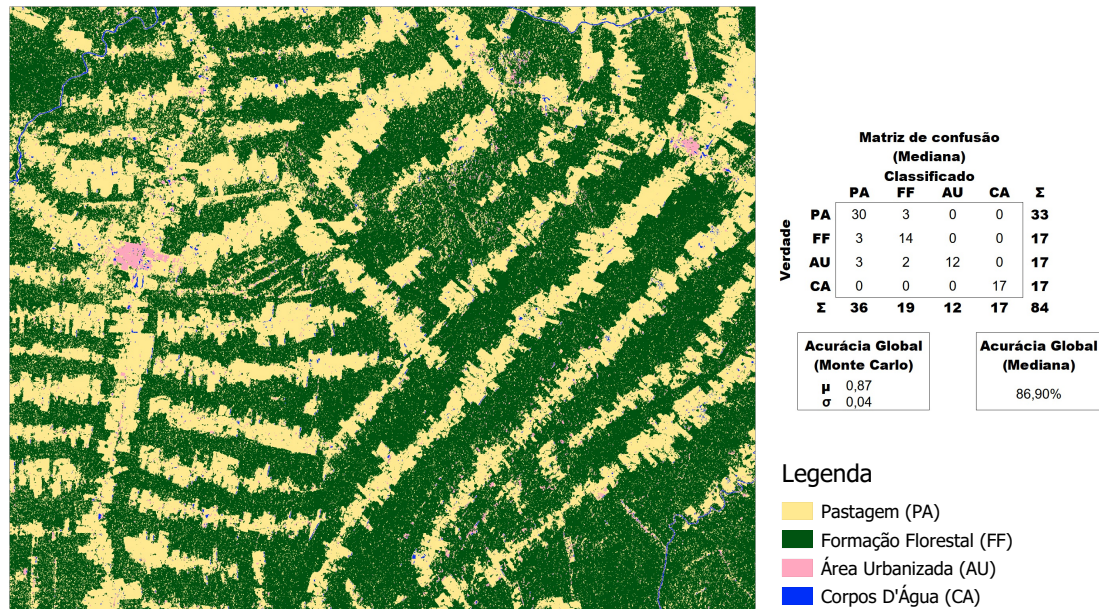
Ao longo das próximas seções, a apresentação dos resultados das classificações ocorrerá da seguinte maneira: serão mostrados os resultados obtidos para as Etapas 1 (cujo principal objetivo é discriminar adequadamente a classe Pastagem das demais classes de uso e cobertura da terra), 2 (cujo objetivo é discriminar as diferentes pastagens baseado na máscara Pastagem obtida na Etapa 1) e 3 (cujo objetivo é estimar indicativos de qualidade das diferentes pastagens obtidas na Etapa 2) para os atributos selecionados da série temporal de radar (Sentinel 1), óptica (Sentinel 2) e para o conjunto de dados combinado.

4.3.1 Classificação de uso e cobertura da terra (Etapa 1)

4.3.1.1 Dados SAR

Após a etapa de seleção de variáveis para os dados de radar, os 18 atributos selecionados (Tabela 4.3) do conjunto de dados derivado da série temporal de dados do Sentinel-1 foram classificados pelo algoritmo *Random Forest*, parametrizado conforme os dados dispostos na Tabela 3.5. Os resultados obtidos para os dados de radar estão ilustrados na Figura 4.18.

Figura 4.18 - Resultado da classificação de uso e cobertura da terra utilizando atributos SAR (Etapa 1).




Fonte: Elaborado pelo autor.

Ao avaliar os resultados obtidos pela classificação dos atributos SAR para a Etapa 1, nota-se que a discriminação das classes que compõem a cobertura da área de interesse ocorre de forma satisfatória, com uma acurácia global média (a partir das 1000 iterações realizadas por meio do experimento Monte Carlo) de $0,87 \pm 0,04$. Entretanto, apesar da excelente discriminação da classe Pastagem, determinada confusão pode ser notada, sobretudo na classe Formação Florestal.

Uma vez que o radar é sensível principalmente a variações topográficas na escala do comprimento de onda, nota-se que a classificação apresenta um aspecto salpicado em virtude não somente da classificação ser pixel a pixel, mas também por conta das microvariações presentes na copa das árvores. Tal efeito pode ser mitigado com a utilização de um filtro contextual como um filtro de moda, por exemplo. Ao considerar elementos de vizinhança, espera-se que pixels espúrios (que tenham sido erroneamente classificados de forma isolada) sejam corrigidos. Em contrapartida, ao utilizar o filtro de moda, uma perda no poder discriminativo das imagens é esperado, uma vez que a classificação agora é realizada, não apenas baseada em um elemento de resolução, mas sim numa janela de *pixels*.

Na matriz de confusão referente à imagem temática apresentada (Figura 4.18), é possível notar a eficiência da classificação utilizando os dados de radar na discriminação de *pixels* correspondentes à Corpos D'Água, dado o reflexo especular esperado, sobretudo em águas interiores (calmas). Entretanto, uma limitação deste tipo de dado pode ser notada em áreas de sombreamento. A confusão na classificação de áreas de sombreamento e de corpos hídricos é frequente, dada a ausência de informação no imageamento de ambas as áreas. Na Figura 4.19 é ilustrada a ocorrência desta limitação na discriminação de elementos próximos a bordas de floresta ou regiões de sombreamento no radar, devido à sua geometria de observação.

Figura 4.19 - Elementos passíveis de confusão presentes na classificação de dados de radar.



A) Recorte da imagem óptica Sentinel-2 (cor natural) de março de 2019; B) Recorte da composição colorida dos atributos SAR e C) Recorte do resultado da classificação dos atributos SAR. Todas as imagens apresentam destaque para a área referida.

Fonte: Elaborado pelo autor.

De forma similar, outra característica limitante relacionada a geometria de observação do sensor radar para este caso, são as áreas onde ocorrem o fenômeno conhecido como *Double Bounce* (em português, Dupla Reflexão). Este fenômeno ocorre em áreas onde a interação da onda com elementos formam um ângulo de 90° (e.g., bordas de floresta) resultando em uma grande quantidade de energia retroespalhada e registrada pelo sensor. Por este comportamento estar bastante relacionado a classe Área Urbanizada, ocorre uma confusão nestas áreas como é possível verificar ainda na Figura 4.19.

Visando a diminuição de ocorrências de confusão (em virtude da geometria de observação do sensor), a utilização de imagens em diferentes configurações de órbita (e.g., órbitas ascendentes) podem auxiliar na geração das métricas temporais, dada a possível ponderação da ausência de informação ou retorno excessivo com informações presentes nestas áreas, que são advindas de observações em órbitas distintas. Outra possibilidade é de utilizar variáveis que consideram o relevo, como visto em FERREIRA et al. (2020). Variáveis como a elevação e declividade, principalmente com a utilização de modelos digitais de elevação mais recentes, podem auxiliar a diminuição destas ocorrências.

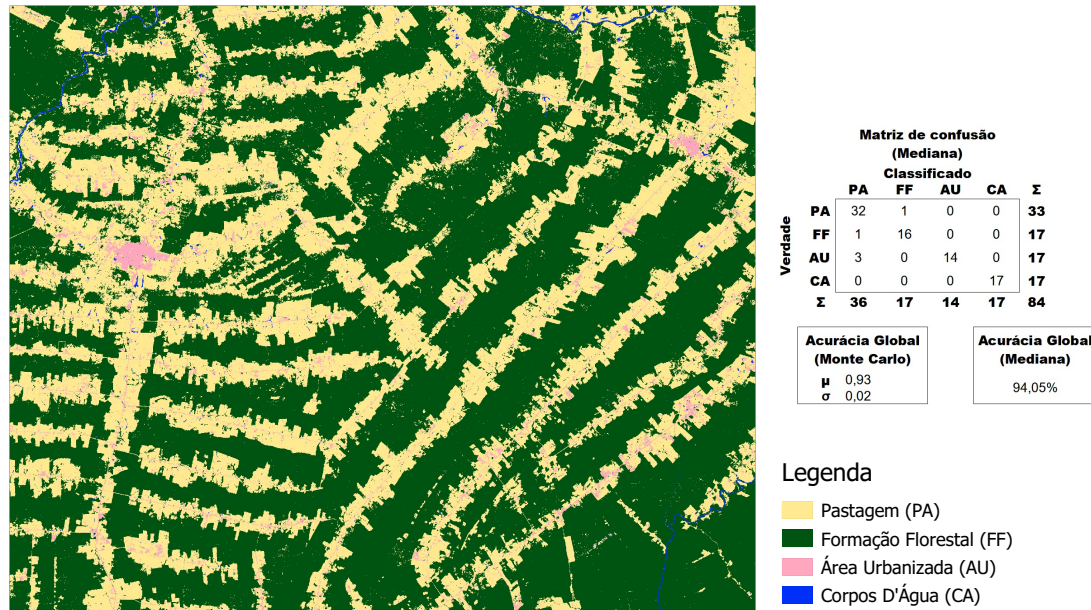
4.3.1.2 Dados ópticos

Após a etapa de seleção de variáveis para os dados ópticos, os 29 atributos selecionados (Tabela 4.5) do conjunto de dados derivado da série temporal de dados do Sentinel-2 foram classificados pelo algoritmo *Random Forest*, parametrizado conforme os dados dispostos na Tabela 3.5. Os resultados obtidos para os dados ópticos estão dispostos na Figura 4.20.

Os resultados de classificação obtidos utilizando os dados ópticos indicam um maior detalhamento e assertividade na discriminação das classes. Tal resultado tem contribuição da grande quantidade de bandas do sensor, capaz de registrar a informação em diferentes partes do espectro eletromagnético e possibilitam uma maior combinação de dados para obtenção de índices que auxiliam na diferenciação das classes de uso e cobertura da terra.

A partir do experimento Monte Carlo com 1000 iterações encontrou-se uma acurácia global média de $0,93 \pm 0,02$. De forma equivalente a apresentação dos resultados obtidos na classificação dos atributos de radar, a imagem temática apresentada corresponde a mediana dos resultados obtidos pelo experimento Monte Carlo, assim como sua matriz de confusão e acurácia global destacada.

Figura 4.20 - Resultado da classificação de uso e cobertura da terra utilizando atributos ópticos (Etapa 1).




Fonte: Elaborado pelo autor.

Apesar do dado óptico ter sido reamostrado para 20m (a fim de compatibilizar com a resolução do dado SAR para comparação) nota-se um maior detalhamento das feições, nos resultados obtidos pela classificação. É importante salientar que os pré-processamentos executados nesta metodologia para utilização adequada dos dados SAR, incluem processos que degradam sua resolução espacial como, por exemplo, o processamento *multilooking* (necessário para padronizar o tamanho da célula de resolução). Além destes, ainda são aplicados filtros redutores de *speckle*, que também contribuem para uma perda na resolução espacial efetiva da imagem. Desta forma, o maior detalhamento de feições era esperado para o dado óptico.

Sobre a menor presença de ruídos, além do conjunto de dados ópticos possuir um número maior de bandas espectrais, este pode estar relacionado a forma como a onda interage com os alvos. Como discutido anteriormente, a onda eletromagnética emitida pelo SAR interage mais fortemente com a topografia dos alvos, é retroespalhada e retorna para o sensor, enquanto que o dado óptico interage mais fortemente com características biofísicas dos alvos. Desta forma há uma possibilidade de determinados alvos na superfície serem melhor descritos segundo seu comportamento sob diferentes comprimentos de onda e não pela capacidade de despolarizar determinada onda ou sua textura como um todo.

Cabe notar que apesar do excelente resultado obtido na classificação do conjunto de dados ópticos (garantido pela matriz de confusão), ruídos relacionados à confusão entre áreas de pastagem (com prevalência de solo exposto) e Área Urbanizada são recorrentes (Figura 4.21A). Estas mesmas ocorrências de *pixels* também se confundem, em menor proporção, com a classe Corpos D'Água (Figura 4.21B). Na Figura 4.21 são ilustradas áreas onde essas confusões ocorreram.

Figura 4.21 - Exemplos de confusões na classificação de dados ópticos: A) Pastagem e Área Urbanizada e; B) Pastagem e Corpos D'Água (erros de comissão).



Fonte: Elaborado pelo autor.


Os *pixels* de Pastagem (com prevalência de solo exposto) que foram erroneamente classificados como Área Urbanizada podem estar relacionados com o fato de que boa parte das estradas do município de Rorainópolis, principalmente nas vicinais de acesso às propriedades rurais, carecem de pavimentação com revestimento asfáltico. Esta característica pode criar uma falsa associação, por impureza dos *pixels* relacionados à Área Urbanizada, com a ocorrência de solo exposto nas pastagens.

Sobre os *pixels* de Pastagem que foram erroneamente classificados como Corpos D'Água, estes podem estar relacionados com a ausência de observações dada a intensa cobertura de nuvens na região, sobretudo na época chuvosa (vide Figura 4.13).

O que pode causar uma tendência das métricas temporais representarem melhor as feições pertinentes à época seca. Na época seca, que é retratada pelo mosaico de imagens obtido no período do trabalho de campo (vide Figura 3.5), pode-se notar, em virtude do baixo nível dos cursos hídricos, o aparecimento de bancos de areia, o que possivelmente induz o classificador ao erro.

Desta forma, com base na máscara de nuvens utilizada para o conjunto de dados ópticos é possível associar uma incerteza (no eixo do tempo) quanto a quantidade de observações livres de nuvens, utilizadas na computação das métricas temporais, insumos para a classificação (Figura 4.22). As cores utilizadas nesta representação estão ligadas ao número de observações utilizadas para compor as métricas temporais, por *pixel*. Portanto, quanto menor o número de observações, pode-se considerar que os valores das métricas temporais computadas para este pixel possuem uma incerteza maior quanto ao registro da sua variabilidade ao longo do tempo e, para os maiores valores, considera-se o oposto.

Figura 4.22 - Número de observações livres de nuvens por pixel para a composição das métricas temporais utilizadas no processo de classificação do conjunto de dados ópticos. Salienta-se que foram utilizados um conjunto de 145 imagens no estudo.



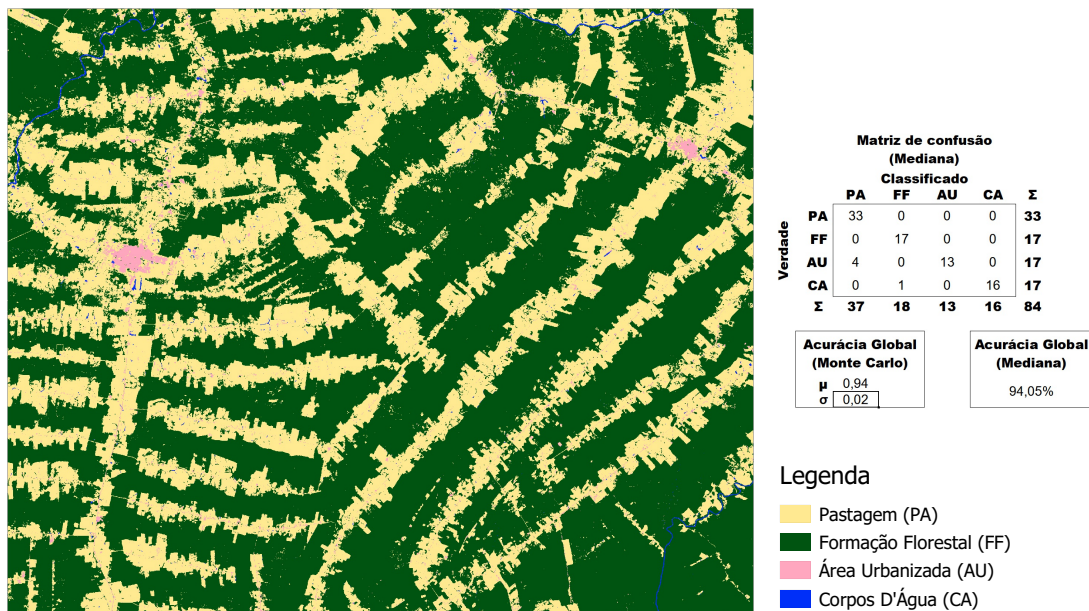
Fonte: Elaborado pelo autor.

Nota-se a partir dos resultados dispostos na Figura 4.22 que a maior parte da área de estudo, dado o regime climático da região, possuem *pixels* com no máximo 59 observações livres de nuvens. Cabe salientar que um total de 145 imagens (2 anos de dados) foram utilizadas para compor as séries, o que corrobora com as confusões observadas na classificação dos dados ópticos. Com base nestes resultados, é evidenciada a importância de se considerar a utilização de um conjunto de dados capaz de integrar dados ópticos e de radar, dada a possibilidade de se ter o registro com menor interferência das constituintes atmosféricas ao longo do tempo.

4.3.1.3 Dados combinados

Para o conjunto de dados combinados (agrupamento de todos os atributos derivado das séries temporais óptica e de radar), após a etapa de seleção de variáveis, os 45 atributos selecionados (Tabela 4.7) foram classificados pelo algoritmo *Random Forest*, parametrizado conforme os dados dispostos na Tabela 3.5. Os resultados obtidos para a classificação dos dados combinados estão dispostos na Figura 4.23.

Figura 4.23 - Resultado da classificação de uso e cobertura da terra utilizando atributos SAR e óptico combinados (Etapa 1).

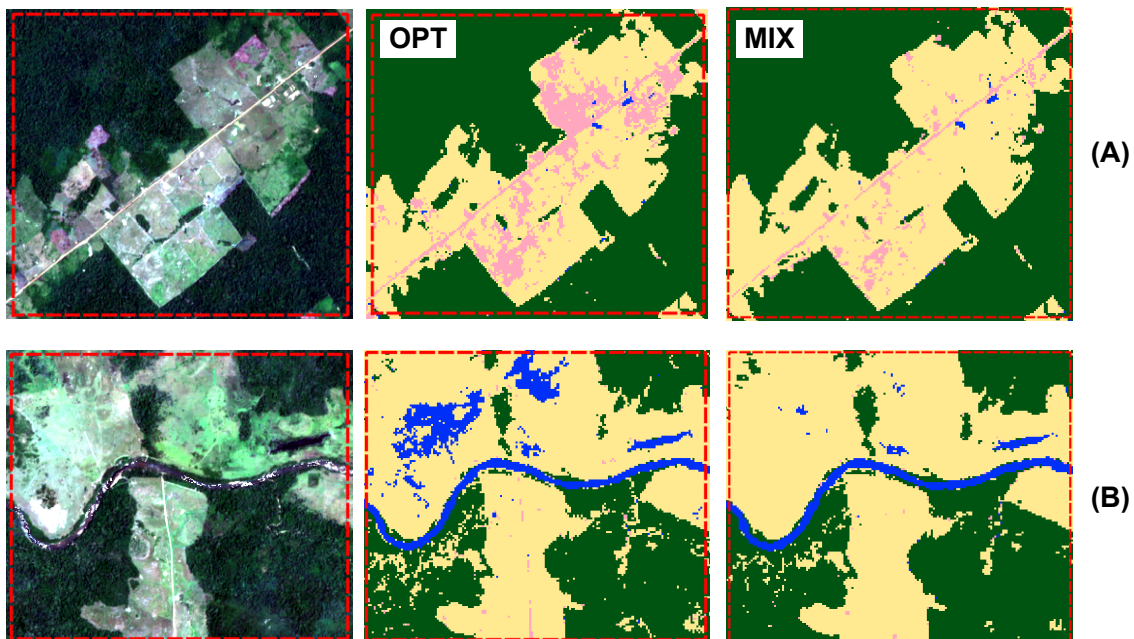


Fonte: Elaborado pelo autor.

Pode-se observar um ganho significativo na diminuição da confusão obtida pelo conjunto de dados ópticos. Entretanto, feições de detalhe como as vias de acesso às propriedades rurais foram minimizados, o que revela uma possível relação de compromisso entre a diminuição da confusão e a perda de elementos de detalhe, que pode ser justificada dada a menor resolução efetiva do radar ou a uma menor sensibilidade do sensor para estas feições.

A partir do experimento Monte Carlo com 1000 iterações encontrou-se uma acurácia global média de $0,94 \pm 0,02$. Ainda que numericamente o resultado da classificação dos dados combinados e dos dados ópticos tenham apresentado valores de acurácia similares, nota-se que os ruídos pertinentes a uma classificação *pixel a pixel* diminuíram consideravelmente bem como as confusões entre a classe Pastagem para com as classes de Área Urbanizada e Corpos D'Água, anteriormente citada. Na Figura 4.24 são mostradas as mesmas áreas utilizadas para ilustrar as confusões obtidas pela classificação dos atributos ópticos.

Figura 4.24 - Exemplos da confusão na classificação usando atributos combinados: (A) Pastagem e Área Urbanizada e (B) Pastagem e Corpos D'Água.




OPT refere-se ao resultado da classificação dos atributos ópticos. MIX refere-se ao resultado da classificação dos atributos combinados.

Fonte: Elaborado pelo autor.

Uma forma sistemática de observar a contribuição da utilização do conjunto de dados combinados em prol de uma única fonte, ocorre por meio das imagens de concordância, obtidos a partir de razões ou diferenças entre os resultados obtidos pelas diferentes classificações. Na Figura 4.25 estão dispostas as imagens de concordância criadas a partir da diferença do resultado das classificações dos conjuntos óptico e SAR; combinado e SAR, e combinado e óptico, respectivamente.

Figura 4.25 - Imagens de concordância entre as classificações para a Etapa 1.



Fonte: Elaborado pelo autor.

Ao analisar a Figura 4.25 é possível notar que as maiores diferenças estão entre os resultados das classificações dos conjuntos de dados ópticos e de radar (concordância de 84,92%), quando separados, dadas as características particulares de cada conjunto de dados já abordadas anteriormente. Já a diferença entre os resultados de classificação dos dados combinado e de radar (concordância de 86,80%), devido à contribuição dos atributos de radar, é menor.

Por fim, ao analisar as diferenças entre os resultados obtidos pelas classificações dos conjuntos de dados combinado e óptico, é possível observar a contribuição da utilização de atributos de radar no que tange a diminuição das inconsistências temáticas, sobretudo na classe Pastagem. Na Tabela 4.9 são apresentadas as áreas de cada classe, com a devida proporção em relação a área total representada da imagem entre parênteses, computadas sobre as diferentes classificações.

Tabela 4.9 - Área (ha) das classes de uso e cobertura do solo para a área de estudo computadas sobre os diferentes resultados de classificação.

Classes	SAR	Óptico	SAR + Óptico
Pastagem	5263,42 (37,88%)	4875,39 (35,08%)	4877,55 (35,10%)
Form. Florestal	8255,64 (59,41%)	8640,14 (62,18%)	8817,99 (63,46%)
Área Urbanizada	292,70 (2,11%)	319,61 (2,30%)	153,06 (1,10%)
Corpos D'Água	82,68 (0,60%)	59,30 (0,43%)	45,85 (0,32%)

Fonte: Elaborado pelo autor.

Com base nos resultados obtidos na computação da área das classes para cada classificação e utilizando como referência os resultados do conjunto de dados combinados, uma breve análise pode ser feita para a classificação da Etapa 1. Pode-se afirmar que as áreas das classes Pastagem, Área Urbanizada e Corpos D'Água foram superestimadas com a classificação dos atributos SAR, dadas as limitações inerentes à geometria de imageamento e comprimento de onda do sensor. Como consequência dessa limitação, a área da classe Formação Florestal foi subestimada.

As áreas obtidas para as classes de Formação Florestal e Pastagem, a partir da classificação com os atributos ópticos, aproximaram-se mais dos valores obtidos pelo conjunto de dados combinados. No entanto, para as classes Área Urbanizada e Corpos D'Água notam-se valores superestimados dadas as confusões atestadas anteriormente (vide Figura 4.24).

Por fim, o teste de McNemar foi aplicado com o intuito de testar a hipótese de que os resultados possuem a mesma proporção de erros, dadas as matrizes de contingência criadas para os cenários de classificação. Na Tabela 4.10 estão sumarizadas as comparações pareadas entre as classificações.

Tabela 4.10 - Resultado do teste de McNemar para as classificações para a Etapa 1, com um nível de significância de 10% ($\chi^2 > 2,706$).

Cenários	Óptico	SAR
SAR + Óptico	0,167*	2,769**
Óptico		5,882**

*: não significativo; **: diferença significativa.

Fonte: Elaborado pelo autor.

Ao observar o resultado apresentado na Tabela 4.10 referente ao teste de McNemar é possível notar que não foi constatada diferenças significativas entre as classificações resultados dos conjuntos de dados ópticos e combinados. No entanto, houveram diferenças entre os resultados das classificações dos conjuntos SAR e combinados, assim como SAR e ópticos. Observa-se que a maior diferença está entre os conjuntos de dados ópticos e SAR, visto que o conjunto de dados combinados já apresenta contribuição dos dados SAR.

Desta forma, a utilização conjunta de dados ópticos e de radar, apesar de custoso devido ao tratamento adequado dos dados de radar, apresenta-se como o melhor cenário para a discriminação das demais classes de uso e cobertura do solo elencadas nesta pesquisa. Pois, visando o monitoramento contínuo em escala compatível com as dimensões do território Amazônico, uma representação mais fidedigna nos resultados de classificação torna-se necessária. No entanto, é necessário considerar que há uma possível relação de compromisso entre a perda de detalhes (e.g., diminuição do detalhamento das vias) e ganho na diminuição de confusões entre as classes (e.g., Pastagem e Área Urbanizada) na utilização de dados combinados, quando comparados a utilização de apenas dados ópticos.

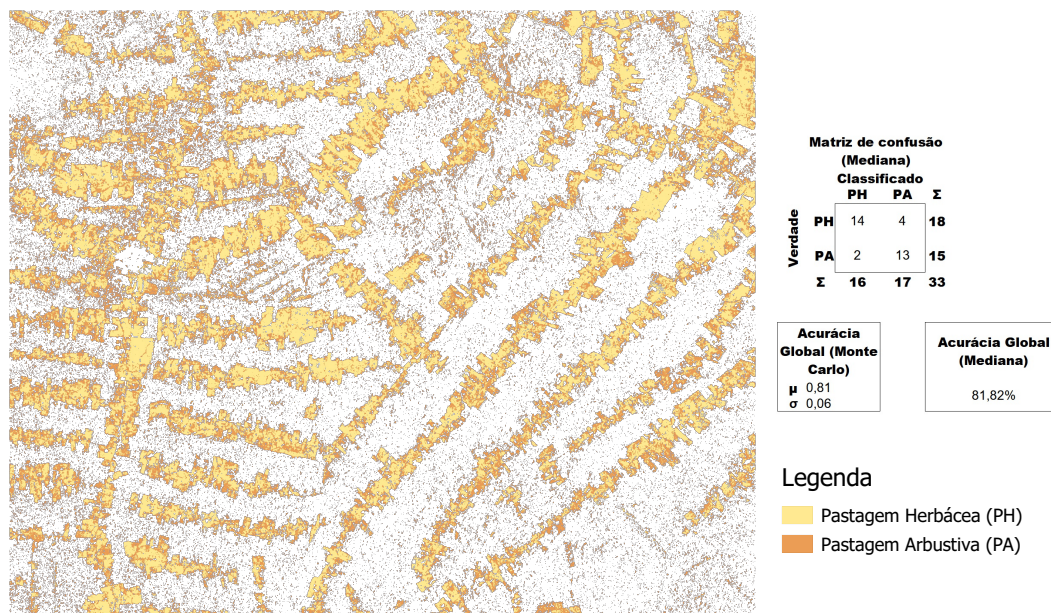
4.3.2 Discriminação das diferentes pastagens (Etapa 2)

4.3.2.1 Dados SAR

Baseado na máscara de Pastagem obtida como resultado da classificação da Etapa 1, na Etapa 2 foram classificados os 30 atributos SAR selecionados na etapa da seleção de variáveis executada para a Etapa 2 (Tabela 4.4). Visando estratificar a classe Pastagem em Pastagem Herbácea e Arbustiva, os dados foram classificados utilizando o algoritmo *Random Forest* parametrizado conforme os dados dispostos na Tabela 3.5. Na Figura 4.26 estão dispostos os resultados obtidos nesta etapa da classificação para os atributos SAR.

De forma análoga à apresentação dos resultados para a Etapa 1, na Figura 4.26 estão dispostos os resultados do experimento Monte Carlo (média e desvio-padrão da acurácia global) bem como a imagem e matriz de confusão referente à mediana dos resultados obtidos pelo experimento.

Figura 4.26 - Classificação dos tipos de pastagem usando atributos SAR (Etapa 2).




Fonte: Elaborado pelo autor.

No resultado para a classificação dos atributos SAR, foi obtida uma acurácia global média (a partir das 1000 iterações realizadas por meio do experimento Monte Carlo) de $0,81 \pm 0,06$. Ruídos pertinentes à classificação pixel a pixel persistiram (fruto da classificação da Etapa 1) bem como se estenderam ao longo das áreas de pastagem. Em aspectos gerais, é possível observar coerência entre os resultados observados no que diz respeito a discriminação das pastagens, sobretudo em transições de pasto para floresta, onde há na maioria das vezes, Pastagens Arbustivas.

Devido ao desempenho obtido pela classificação dos dados SAR para a Etapa 2, cabe salientar que estes mesmos atributos podem ser utilizados para discriminar as diferentes classes de pastagens com base em outras máscaras, o que pode fornecer um maior detalhamento de dados já existentes. Na Figura 4.27 estão dispostas: (A) a imagem de satélite Sentinel-2 (cor natural) para o período de campo (março/2019) e (B) o resultado da classificação obtida na Etapa 2. As setas brancas destacam a ocorrência da classe Pastagem Arbustiva nas duas imagens.

Figura 4.27 - Exemplos de áreas classificadas como Pastagem Arbustiva, destacados pelas setas brancas, com base nos atributos de radar.



■ Pastagem Herbácea ■ Pastagem Arbustiva ■ Formação Florestal ■ Área Urbanizada ■ Corpos D'Água

(A) Imagem Sentinel-2 (cor natural) de março/2019. (B) Resultado da classificação para a Etapa 2 utilizando os dados de radar.

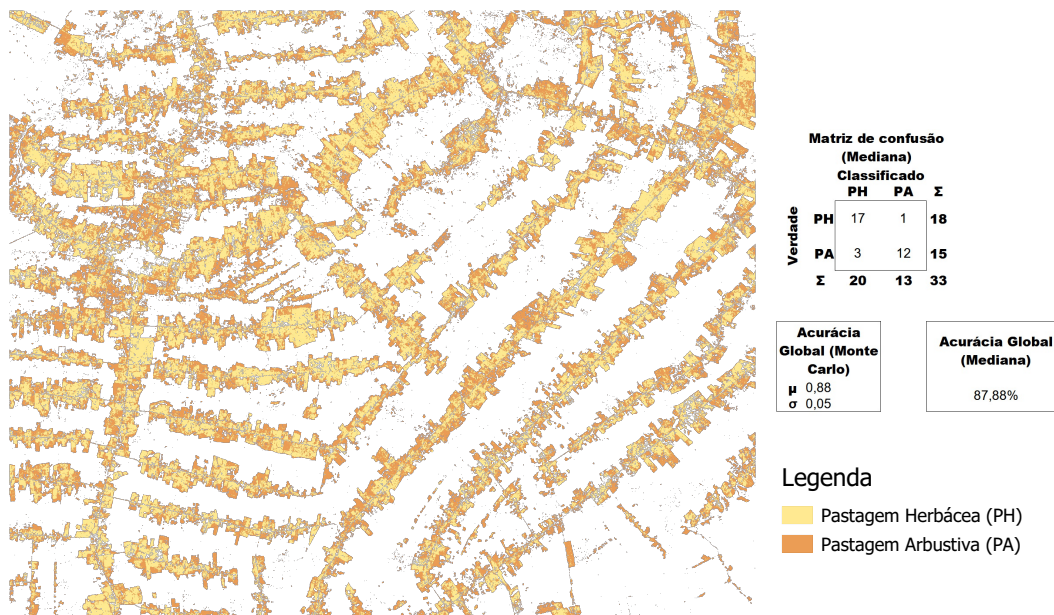
Fonte: Elaborado pelo autor.

4.3.2.2 Dados ópticos

Na classificação dos dados ópticos para a Etapa 2 (Figura 4.28), utilizando como base a máscara de Pastagem obtida na Etapa 1, foram classificados os 36 atributos ópticos selecionados na etapa da seleção de variáveis executada para a etapa (Tabela 4.6). Visando estratificar a classe Pastagem em Pastagem Herbácea e Arbustiva, os dados foram classificados utilizando o algoritmo *Random Forest* parametrizado conforme os dados dispostos na Tabela 3.5. Na Figura 4.28 estão dispostos os resultados obtidos nesta etapa da classificação para os atributos ópticos.

De forma análoga à apresentação dos resultados para a Etapa 1, na Figura 4.28 estão dispostos os resultados do experimento Monte Carlo (média e desvio-padrão da acurácia global) bem como a imagem e matriz de confusão referente à mediana dos resultados obtidos pelo experimento. Foi obtida uma acurácia global média de $0,88 \pm 0,05$. Dada a obtenção da máscara com menor ocorrência de ruídos e maior acurácia (resultados obtidos na Etapa 1), notam-se definições mais claras dos limites das pastagens resultando em uma melhor definição das classes Pastagem Herbácea e Arbustiva.

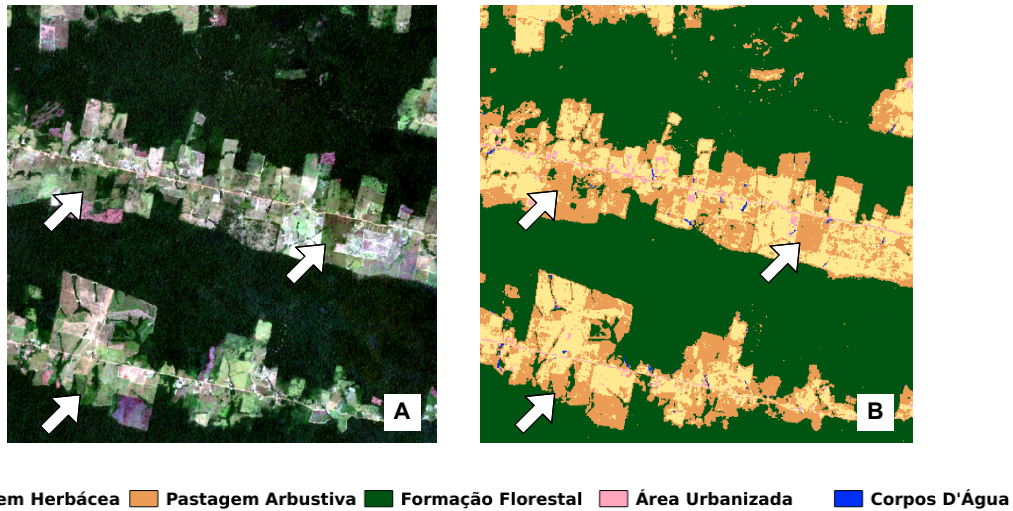
Figura 4.28 - Classificação dos tipos de pastagem usando atributos ópticos (Etapa 2).



Fonte: Elaborado pelo autor.

Com o intuito de visualizar os mesmos exemplos de Pastagem Arbustiva observados para a classificação SAR na seção anterior (Figura 4.27), na Figura 4.29 estão dispostas da mesma forma: (A) a imagem de satélite Sentinel-2 (cor natural) para o período de campo (março/2019) e (B) o resultado da classificação obtida na Etapa 2. O destaque com as setas brancas evidenciam a ocorrência da classe Pastagem Arbustiva nas duas imagens.

Figura 4.29 - Exemplos de áreas classificadas como Pastagem Arbustiva, destacados pelas setas brancas, com base nos atributos ópticos.



(A) Imagem Sentinel-2 (cor natural) de março/2019. (B) Resultado da classificação para a Etapa 2 utilizando os dados ópticos.

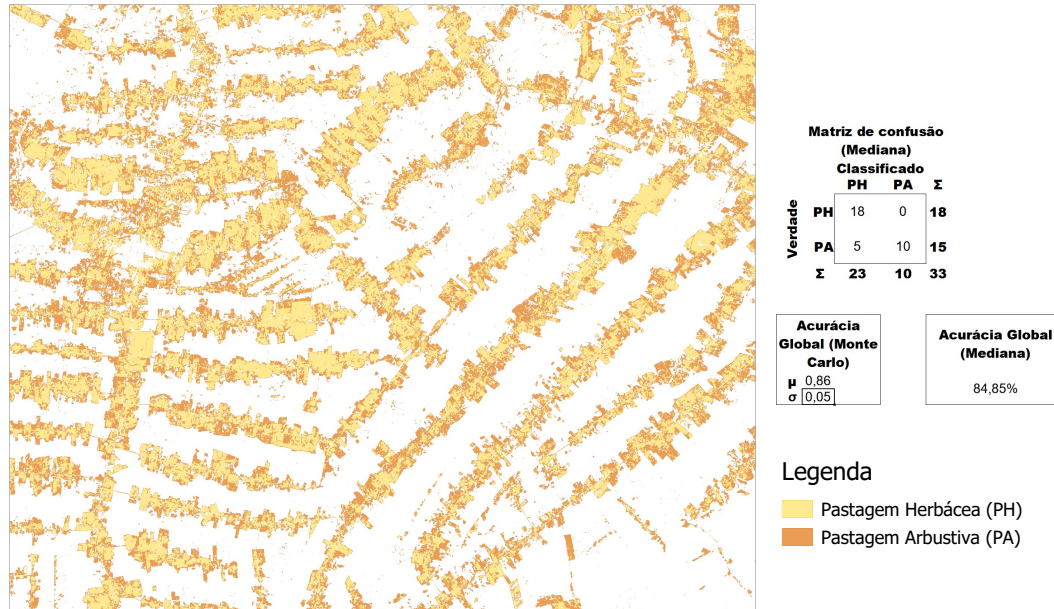
Fonte: Elaborado pelo autor.

4.3.2.3 Dados combinados

Para a classificação dos dados combinados na Etapa 2 (Figura 4.30), utilizando como base a máscara de Pastagem correspondente obtida na Etapa 1, foram classificados os 64 atributos ópticos e de radar que compuseram o conjunto de dados combinados; selecionados na etapa da seleção de variáveis (Tabela 4.8). Visando estratificar a classe Pastagem em Pastagem Herbácea e Arbustiva, os dados foram classificados utilizando o algoritmo *Random Forest* parametrizado conforme os dados dispostos na Tabela 3.5. Na Figura 4.30 estão dispostos os resultados obtidos nesta etapa da classificação para os atributos combinados.

Na Figura 4.30 estão dispostos os resultados do experimento Monte Carlo (média e desvio-padrão da acurácia global) bem como a imagem e matriz de confusão referente à mediana dos resultados obtidos pelo experimento. Foi obtida uma acurácia global média de $0,88 \pm 0,05$. Dada a obtenção da máscara com menor ocorrência de ruídos e maior acurácia (resultados obtidos na Etapa 1), notam-se definições mais claras dos limites das pastagens resultando em uma melhor definição das classes Pastagem Herbácea e Arbustiva.

Figura 4.30 - Classificação dos tipos de pastagem usando atributos SAR e ópticos (Etapa 2).

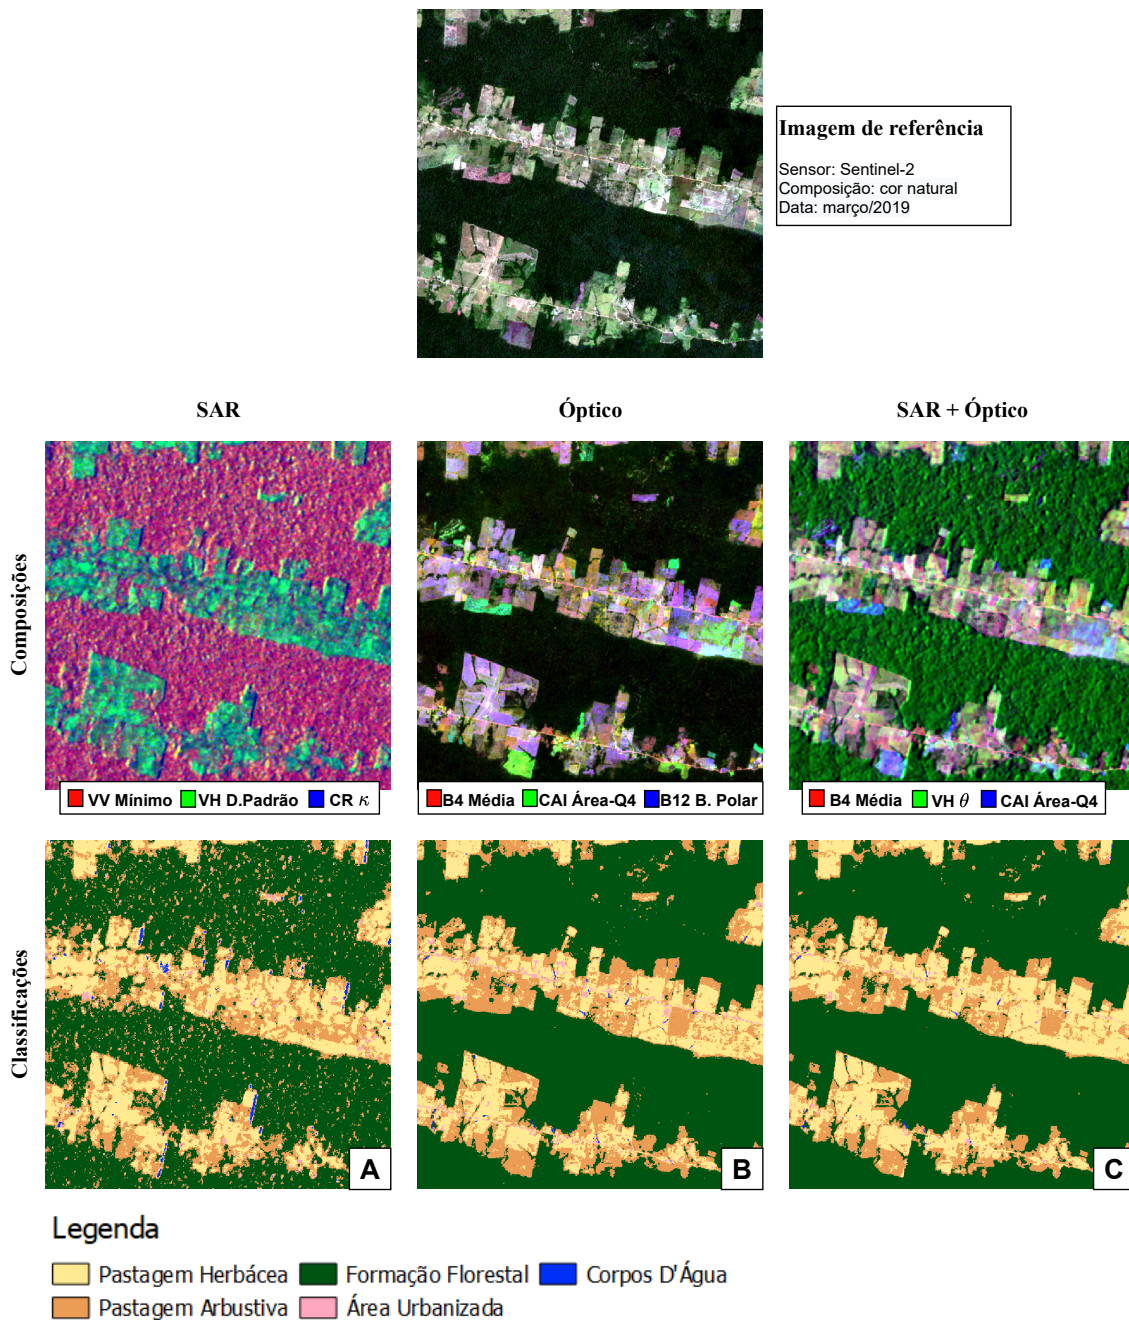


Fonte: Elaborado pelo autor.

Em termos de acurácia global, nota-se a obtenção de valores mais baixos para a classificação com os atributos combinados para a Etapa 2, quando comparados aos valores obtidos pela classificação óptica. Tal fato pode indicar que apenas o conjunto de dados ópticos já é suficiente para separar as duas classes entre si. Entretanto, ainda é necessário verificar se existem diferenças significativas entre os resultados. Caso confirmada, a utilização de um conjunto combinado para a geração da máscara na Etapa 1 e de apenas um conjunto de dados óptico para separação dos tipos de pastagem pode ser suficiente para o monitoramento anual, o que não inviabiliza a utilização dos dados SAR na ausência de imagens ópticas, numa eventual necessidade de monitoramento em condições atmosféricas adversas ao sensor óptico.

Na Figura 4.31 são mostrados recortes da área de estudo equivalentes nas classificações dos diferentes conjuntos de dados para comparação visual dos resultados obtidos. Com resultados bem similares entre as classificações dos conjuntos de dados óptico e combinado, é possível notar feições ligeiramente melhor definidas nos resultados da classificação do conjunto de dados combinados.

Figura 4.31 - Recorte dos resultados de classificação para os conjuntos: (A) SAR, (B) Óptico e (C) Combinado. Adicionalmente estão dispostas as composições coloridas representativas para a Etapa 2 de cada conjunto de dados.



Fonte: Elaborado pelo autor.

Para a observação de forma sistemática das concordâncias entre as classificações, similarmente ao que foi adotado para a Etapa 1, foram computadas imagens de diferença entre as classificações, adotando a classificação óptica como referência desta vez. Na Figura 4.32 estão dispostas as diferenças entre o resultado da classificação dos três conjuntos de dados para a Etapa 2.

Figura 4.32 - Imagens resultado da diferença entre as classificações para a Etapa 2.



Fonte: Elaborado pelo autor.

Com o intuito de comparar a decisão do classificador apenas em áreas de pastagens, em cada um dos cenários é possível observar o restante das classes discriminadas nas cores branca (para áreas de concordância entre as classificações) e vermelha (para áreas não concordantes). O mesmo padrão obtido na Etapa 1 pode ser observado para a Etapa 2, nos quais a maior concordância está presente entre os resultados gerados pela classificação dos dados ópticos e combinados. E, a menor, presente entre os resultados das classificações dos dados ópticos e SAR.

A área, juntamente com a proporção de cada uma das pastagens pode ser observada na Tabela 4.11. É possível observar uma proporção similar entre a área das classes, nos conjuntos de dados classificados. Para a classificação com atributos SAR, observa-se uma subestimativa da máscara, como pôde ser avaliado na Etapa 1. Em virtude desta confusão, uma superestimativa da classe Pastagem Arbustiva foi obtida. Entretanto, para a classe Pastagem Herbácea, observa-se que há um valor equivalente em todas as classificações, o que indica uma concordância relevante entre as classificações, remetendo à uma capacidade de discriminação similar desta classe. A maior diferença observada foi para a classe Pastagem Arbustiva, com uma diferença de 1,66% entre a classificação óptica e combinada e entre as classificações óptica e SAR de 1,36%.

Tabela 4.11 - Área (ha) relativas as classes de pastagens resultado da classificação para a Etapa 2.

Classes	SAR	OPT	MIX
Máscara	8631,02(62,11%)	9019,05(64,91%)	9016,89(64,89%)
Pastagem Herbácea	2447,80(17,61%)	2248,99(16,18%)	2481,56(17,86%)
Pastagem Arbustiva	2815,62(20,26%)	2626,40(18,90%)	2395,98(17,24%)

Fonte: Elaborado pelo autor.

Por fim, foi aplicado o teste de McNemar para atestar se houve diferenças significativas na classificação das diferentes pastagens para os conjuntos de dados testados e os resultados estão dispostos na Tabela 4.12. Com base no teste com um nível de significância de 10%, foi possível atestar que todas as classificações possuem diferentes proporções de erros, o que indica que possuem diferenças significativas nos seus resultados. Deste modo, a classificação que apresentou melhor resultado para diferenciação das pastagens, foi a classificação com o conjunto de dados ópticos, sendo suficiente, considerando a metodologia proposta, para a discriminação dos diferentes tipos de pastagens para essa região de estudo.

Tabela 4.12 - Resultado do teste de McNemar para as classificações para a Etapa 2, com um nível de significância de 10% ($\chi^2 > 2,706$).

Cenários	Óptico	SAR
SAR + Óptico	5,143**	9,091**
Óptico		12,071**

*: não significativo; **: diferença significativa.

Fonte: Elaborado pelo autor.

4.4 Indicativos de qualidade das pastagens - (Etapa 3)

Como abordado no Capítulo 2, as pastagens podem ser degradadas de forma agrícola ou biológica. Na primeira há a competição de outras espécies de vegetação e na segunda há a perda de nutrientes do solo resultando no enfraquecimento das forrageiras resultando na ocorrência de solo exposto (DIAS-FILHO; ANDRADE, 2006).

Com base na metodologia proposta no Capítulo 3, os indicativos de degradação serão obtidos por meio da utilização do $NDVI_m$, para os dados ópticos. O $NDVI_m$ corresponde ao atributo de mediana da série temporal de NDVI normalizado pelos valores do 1° e 99° percentil (para ocorrência de valores entre 0 e 1). Como resultado, foram estimados diferentes níveis de degradação baseado num intervalo de valores dispostos entre zero e um. Já para os dados SAR, por este não possuir um atributo diretamente relacionado ao vigor vegetativo como o NDVI, no caso óptico, optou-se por realizar uma regressão linear múltipla com a contribuição de diferentes atributos.

4.4.1 Dados ópticos

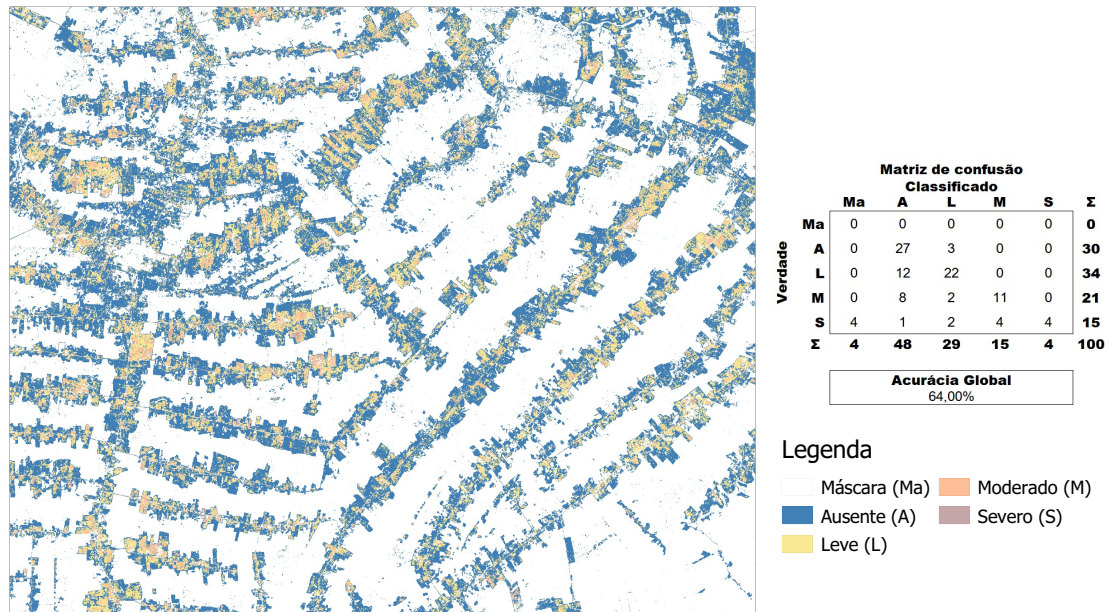
Dentre as relações existentes entre o NDVI e a vegetação, pode-se destacar a relação do sinal refletido com o vigor vegetativo. Desta forma, ao realizar a avaliação das pastagens por este índice, são esperados valores baixos de NDVI para pastagens degradadas de forma biológica, uma vez que a resposta do solo prevaleceria, diferentemente de uma pastagem saudável, por exemplo.

A mesma relação quando feita para a degradação agrícola é inconclusiva. Pois a presença de espécies invasoras não irá necessariamente alterar os valores de NDVI, podendo em alguns casos até elevar estes valores, devido ao aumento da biomassa. Portanto, dada esta possível limitação, será avaliado basicamente o potencial da discriminação dos diferentes níveis de degradação biológica das pastagens com base nas amostras considerando a interpretação proposta na seção 3.4.3.

Com base nos dados da série temporal de NDVI, foi computada uma imagem de mediana dos *pixels* e posteriormente esta foi normalizada pelos valores do 1° e 99° percentis da série temporal de NDVI (equivalente aos valores máximos e mínimos da série, desconsiderando possíveis *outliers*), visando a obtenção de indicativos de degradação como resultado. Após o cômputo do $NDVI_m$ normalizado e com a aplicação da máscara de Pastagem (obtida na Etapa 1 - conjunto de dados óptico) foi realizado o fatiamento para obtenção dos indicativos de degradação Severa ($NDVI_m \leq 0,4$), Moderada ($0,4 < NDVI_m \leq 0,5$), Leve ($0,5 < NDVI_m \leq 0,6$) e Au-

sente ($NDVI_m > 0,6$). Na Figura 4.33, estão dispostos os resultados do fatiamento do $NDVI_m$ para geração dos indicadores de degradação.

Figura 4.33 - Indicativos de degradação para as Pastagens, obtidos pelo fatiamento do $NDVI_m$ normalizado.



Fonte: Elaborado pelo autor.


Com uma acurácia global de 64% é possível observar que houve pequenas inconsistências herdadas das máscaras de pastagem (Ma), conforme ilustrado na matriz de confusão. Dadas as amostras utilizadas para análise, as maiores confusões ocorreram entre as classes Ausente (Au) e Baixo (B) indicativo de degradação. Com relação as 15 amostras da classe Alto (A) indicativo de degradação, apenas quatro foram classificadas corretamente, com o restante das suas amostras distribuídas erroneamente entre as demais classes.

Devido à utilização de dados estáticos no tempo (i.e., imagem de referência da campanha de campo) para obtenção da verdade quanto ao estágio de degradação das amostras de pasto, a ocorrência de inconsistências são esperadas na etapa de validação dado que são utilizadas informações provenientes de métricas temporais (que representam as variações ao longo do tempo) para geração dos indicadores de degradação. Deste modo, é prudente que sejam avaliadas outras formas de validar

a degradação de pastagens, devido a sensibilidade destas para ocorrências como as chuvas, por exemplo, que podem elevar os níveis de NDVI mascarando a ocorrência de um processo de degradação, se observados uma única vez ao longo do tempo.

Dentre os mapeamentos de indicadores de degradação, o projeto Mapbiomas fornece imagens para todo o Brasil de qualidade das pastagens. Com metodologia similar, o produto é feito com base em coleções de imagens Landsat para os anos de 2010 e 2018. Até a data desta pesquisa o produto ainda encontra-se em fase experimental, o que resulta numa ausência de indicadores de validação. Na Figura 4.34 estão dispostos os resultados de qualidade de pastagens do Mapbiomas para a região de interesse.

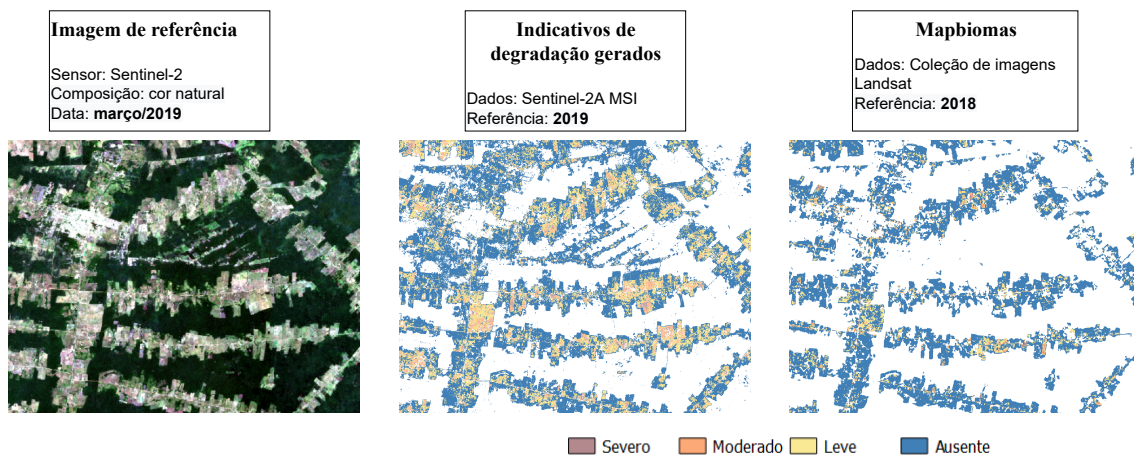
Figura 4.34 - Indicativos de qualidade de pastagens do Mapbiomas para a região, para o ano de 2018.



Fonte: Mapbiomas (2020).

Na Figura 4.35 estão dispostos recortes da imagem de referência para a pesquisa, dos indicativos de degradação gerados pelo fatiamento do $NDVI_m$ e do dado disponível pelo Mapbiomas para qualidade das pastagens para o ano de 2018 para efeito de comparação. é possível avaliar que há uma diferença considerável na atribuição dos indicativos de degradação. Além da diferença temporal do dado disponível pelo Mapbiomas, a metodologia proposta por esta pesquisa utilizando dados do Sentinel-2 pode oferecer resultados mais detalhados nos quesitos de resolução espacial (10 m), resolução temporal (com um maior número de observações dado seu menor intervalo de revisita) e resolução espectral (devido ao maior número de bandas), possibilitando a computação de novos índices e da utilização de bandas da borda do vermelho, por exemplo.

Figura 4.35 - Comparação dos indicativos de degradação obtidos pelo fatiamento do $NDVI_m$ gerado na pesquisa e dos dados disponibilizados pelo Mapbiomas.



Fonte: Elaborado pelo autor.

4.4.2 Dados SAR

Na utilização de dados SAR, uma regressão linear múltipla foi empregada com os atributos SAR para obtenção de uma relação com o NDVI normalizado. Deste modo, a equação obtida pelo método *stepwise* (que consiste numa busca passo a passo no acréscimo ou decréscimo de atributos na equação, visando a melhoria na capacidade de descrição do modelo) é expressa por:

$$NDVI_{SAR} = 0,21 + 2,72a - 16,11b - 176,22c + 1,28d + 0,03e + 4,84f \quad (4.1)$$

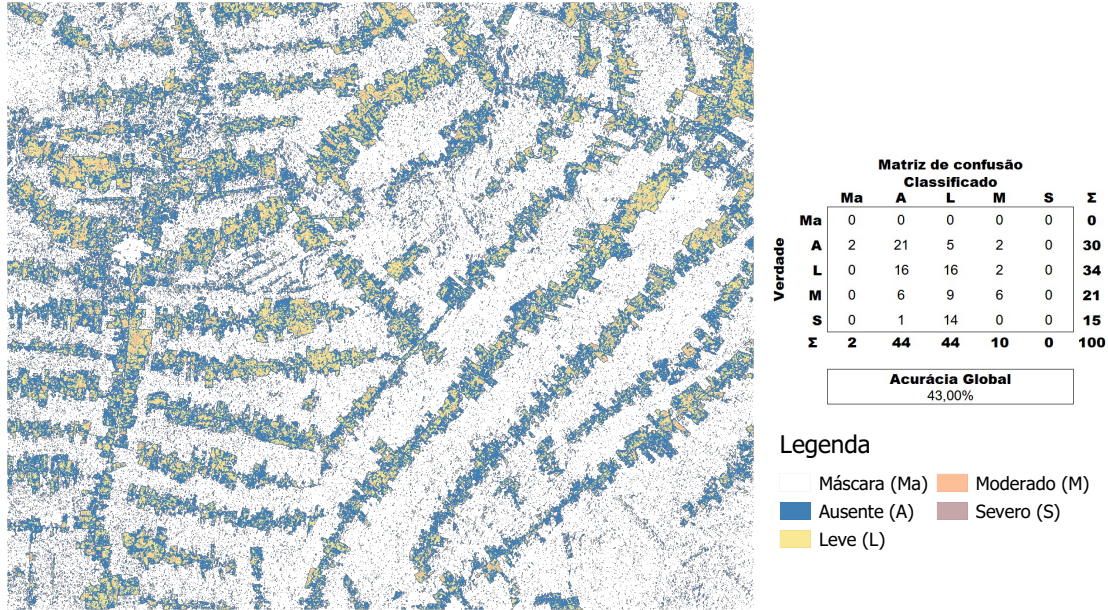
onde a corresponde a mediana da série temporal da polarização VV; b ao desvio-padrão da série temporal da polarização VH; c ao balanço polar da série temporal da polarização VH; d a área polar do quarto quadrante da série temporal do índice CR; e a morfologia da geometria polar (CSI) da série temporal do índice RVI; e f ao desvio-padrão da série temporal da polarização VV.

Com um $r^2 = 0,6$ nota-se que foi possível a construção de uma relação para a obtenção de indicativos de degradação com dados SAR, com base nos atributos das séries temporais. Após a obtenção da imagem resultante, na Figura 4.36 está ilustrado o fatiamento realizado para obtenção dos indicativos de degradação.

Com a obtenção de uma acurácia global de 43%, foi possível realizar a geração de indícios de degradação baseado em atributos SAR, por meio da realização de uma regressão linear múltipla com o NDVI normalizado. As maiores confusões ocorreram entre as classes Ausente e Baixo indicativo de degradação, e Baixo e Alto indicativo de degradação, respectivamente. Dos 100 pontos utilizados para essa validação, apenas 2 ficaram fora da máscara de pastagem (herança da Etapa 1 de classificação para os dados SAR).

Nota-se que não houve detecção alguma sequer, para as amostras pertencentes ao Alto indicativo de degradação. Deste modo, pode-se inferir que os dados de radar, para este comprimento de onda (banda C), polarizações e resolução, apresenta-se menos sensível a presença de solo exposto nas pastagens, podendo esta questão estar associada a pouca diferença na rugosidade das superfícies em questão. A computação das áreas pertinentes a tais classes, assim como suas proporções estão dispostas na Tabela 4.13.

Figura 4.36 - Indicativos de degradação para as pastagens, obtidos pelo fatiamento do $NDVI_{SAR}$.



Fonte: Elaborado pelo autor.

Tabela 4.13 - Área (ha) e proporção das classes de indicativos de degradação de pastagens presentes na área de estudo.

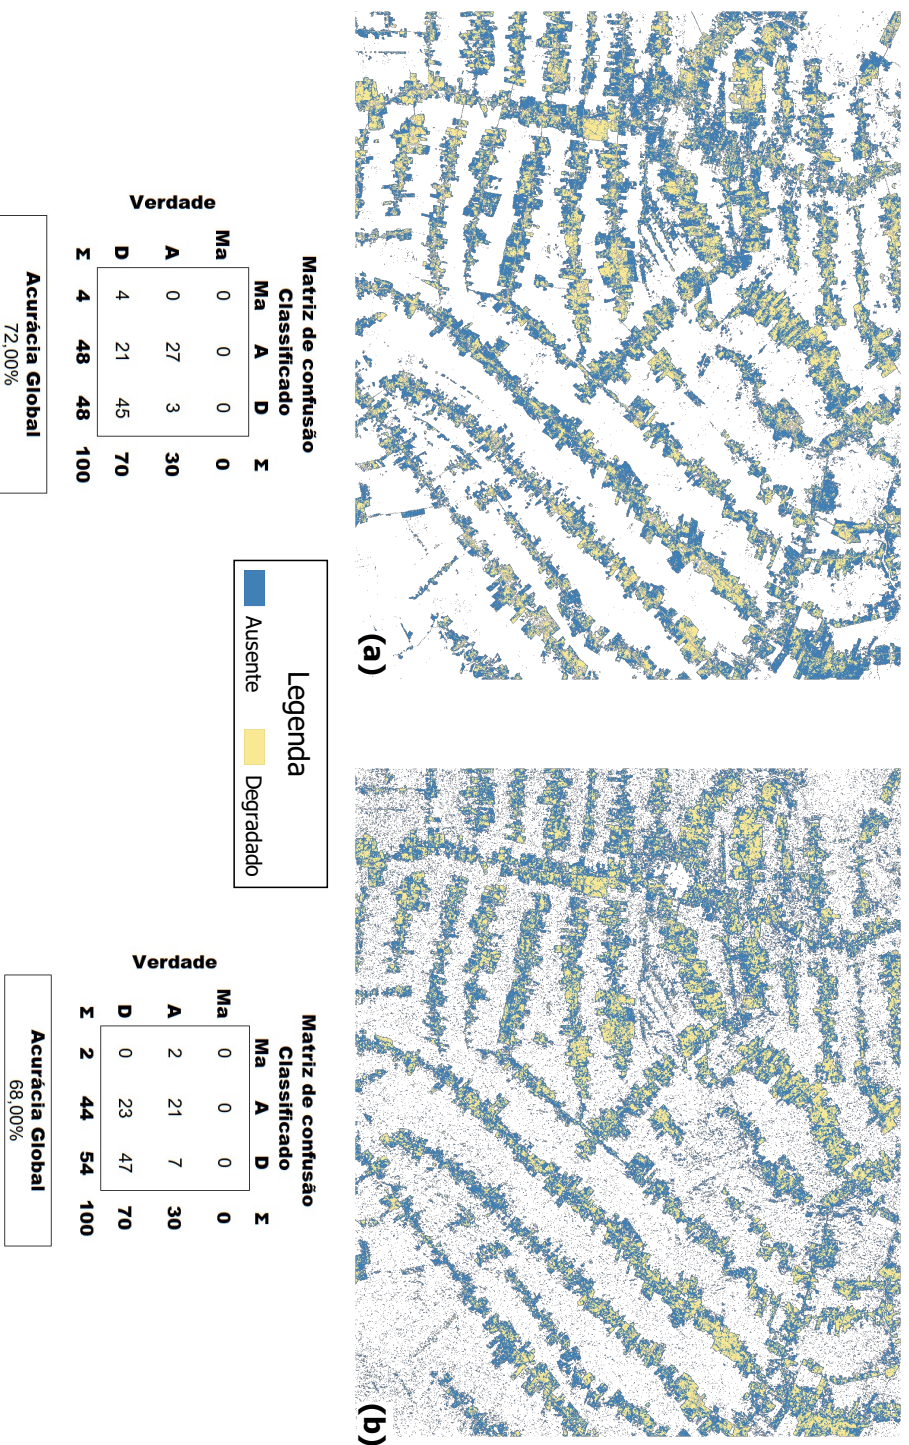
Classes	SAR	OPT
Máscara	8631,06(62,12%)	9019,16(64,91%)
Ausente	3859,08(27,77%)	3392,40(24,42%)
Baixo	1192,54(8,58%)	1090,60(7,85%)
Médio	198,88(1,43%)	344,46(2,48%)
Alto	12,87(0,09%)	47,83(0,34%)

Fonte: Elaborado pelo autor.

No geral, notaram-se proporções similares entre os resultados obtidos por ambos os conjuntos de dados. As maiores discrepâncias, desconsiderando as decorrentes da classe Máscara, estão presentes nas classes de Ausente e Médio indicativos de degradação, respectivamente. É possível observar, considerando o óptico como referência, que houve uma menor sensibilidade para as classes de Médio e Alto indicativos de degradação.

Baseado no número de amostras desbalanceado entre as classes de indicativos de degradação e dadas as limitações encontradas nas classificações dos conjuntos de dados ópticos e SAR, optou-se por generalizar o número de classes de indicativos de degradação para apenas Ausente e Degradado, agregando os níveis de Baixo, Médio e Alto apenas na classe Degradado. Na Figura 4.37 são mostrados os resultados para os dados óptico (Figura 4.37a) e para os dados SAR (Figura 4.37b).

Figura 4.37 - Resultado dos indicadores de degradação considerando apenas 2 classes, para o conjunto de dados: (a) óptico e (b) SAR.



Fonte: Elaborado pelo autor.

Ao realizar a generalização nota-se que a acurácia, sobretudo dos resultados obtidos pela classificação dos dados SAR, se eleva visto que agora são desconsideradas quaisquer diferenças entre as degradações. Ainda em termos de acurácia, é possível notar que os resultados equiparam-se com uma diferença de apenas 4% entre as classificações dos conjuntos de dados óptico e SAR. Os valores de áreas e as proporções das classes estão dispostos na Tabela 4.14.

Tabela 4.14 - Área (ha) e proporção das classes de indicativos de degradação de pastagens presentes na área de estudo.

Classes	SAR	Óptico
Máscara	8631,06(62,12%)	9019,16(64,91%)
Ausente	3859,08(27,77%)	3392,40(24,42%)
Degradado	1404,30(10,11%)	1482,89(10,67%)

Fonte: Elaborado pelo autor.


Com base na observação das áreas de cada uma das classes, nota-se que as proporções ficam muito próximas em números absolutos. Entretanto as áreas diferem na classe Ausente aproximadamente 466 *ha*, seguido pela classe máscara (herança da Etapa 1 do processo de classificação). Como forma de espacializar a concordância nas classificações, foi computada a imagem de diferença entre os resultados de indicativos obtidos por meio dos conjuntos de dados SAR e óptico (Figura 4.38).

A maior parte das diferenças, como mencionado anteriormente, apesar de ser na classe Ausente, ocorrem por conta das diferentes máscaras, seguidos pela diferença quanto a ausência ou não de indicativos de degradação. Além das diferentes resoluções e sensibilidades dos conjuntos de dados quanto à rugosidade dos elementos que compõem as diferentes degradações, ainda há a questão de que o índice $NDVI_{SAR}$ foi computado a partir de uma regressão linear múltipla dos atributos de radar com um $r^2 = 0,6$ o que possivelmente já inclui algumas incertezas.

Por fim, com base nos resultados obtidos, pode-se derivar um fluxo de processamento mais adequado para a região considerando, para a Etapa 1, os dados combinados (SAR+óptico) para obter uma melhor representação, com menor incidência de inconsistências (passíveis de ambos os conjuntos de dados - OPT e SAR, separadamente). No entanto, em termos de acurácia, não houve diferenças significativas entre os resultados obtidos por meio do conjunto de dados óptico.

Figura 4.38 - Imagem de concordância entre os indicadores de degradação gerados pelos conjuntos de dados SAR e óptico.

(Óptico - SAR)



Concordância: 77,37%

□ **Concordância** ■ **Diferença**

Fonte: Elaborado pelo autor.

Após a obtenção da máscara de pastagens, o resultado da separação das diferentes pastagens por meio do conjunto de dados óptico obteve uma acurácia maior, dada sua maior capacidade de discriminação espectral. No entanto, com base em uma máscara preexistente, o conjunto de dados SAR mostrou-se eficiente na separação das pastagens em Herbáceas e Arbustivas também, devido sua capacidade efetiva de registrar, com um número maior de observações, mudanças menos abruptas ao longo do tempo. Dado que a classe Pastagem Arbustiva, na ocorrência de chuvas, sofria mudanças menos abruptas quando comparada a classe de Pastagem Herbácea, cabe considerar seu uso nestas situações.

Na obtenção dos diferentes níveis de degradação, o conjunto de dados ópticos se mostrou mais eficiente na separação de mais estágios, no entanto, em termos de acurácia, equipara-se com o resultado obtido pelo conjunto de dados SAR, se consideradas apenas duas classes: Ausente e Degradado. Contudo, é importante salientar que outros métodos de validação e formas de abstração da degradação por meio de dados SAR devem ser empregados/estudados para avaliar de forma mais robusta o potencial de diferenciação dos dados remotos para geração de indicadores de degradação das pastagens.

Com a utilização de um fluxo combinado, dadas as diferentes acurácias obtidas nos resultados da classificação dos conjuntos de dados óptico, SAR e combinado, é possível obter um resultado capaz de sintetizar, o quão degradado estão as diferentes pastagens. Na Figura 4.39 é ilustrada a distribuição espacial das pastagens Herbácea e Arbustiva, associadas aos indicativos de degradação. Nota-se que a maior parte da sensibilidade da degradação está, de fato, relacionada com a pastagem herbácea, o que reforça a questão relacionada a limitação de uma análise de degradação considerando apenas o NDVI. Na Tabela 4.15, estão dispostos os valores de área e suas proporções para a contabilização das pastagens segundo suas diferentes classes e indicativos de degradação, para obtenção de um panorama geral conclusivo das pastagens presentes na área de estudo.


Tabela 4.15 - Área (ha) e proporção das classes de pastagem associadas aos indicativos de degradação presentes na área de estudo.

Classes	Pastagem Herbácea	Pastagem Arbustiva	TOTAL
Máscara	9016, 894(64, 90%)		9016, 894(64, 90%)
Ausente	926, 77(6, 67%)	2351, 92(16, 93%)	3278, 69(23, 60%)
Baixo	1039, 27(7, 48%)	85, 08(0, 61%)	1124, 35(8, 09%)
Médio	372, 16(2, 68%)	2, 87(0, 02%)	375, 03(2, 70%)
Alto	98, 76(0, 71%)	0, 51(0, 003%)	99, 27(0, 71%)

Fonte: Elaborado pelo autor.

Desta forma é possível concluir que na área de estudo, aproximadamente 67% das pastagens (28% para Pastagens Herbáceas e 71% para Pastagens Arbustivas) não apresentam nenhum indicativo de degradação, segundo a metodologia empregada na análise. Cerca de 23% das pastagens (92% para Pastagem Herbácea e 7,5% para Pastagem Arbustiva) apresentam um indicativo de degradação Baixo. Apresentam um indicativo de degradação Médio cerca de 7,7% das pastagens (99% para Pastagens Herbáceas) e Alto com cerca de 2% (99% para Pastagens Herbáceas).

Figura 4.39 - Distribuição espacial das classes Pastagem Herbácea e Arbustiva, associadas à 4 níveis de degradação.



Produto gerado com base em atributos derivados de séries temporais óptica (Sentinel-2) e SAR (Sentinel-1).

Fonte: Elaborado pelo autor.

5 CONCLUSÕES E RECOMENDAÇÕES

Neste trabalho de dissertação objetivou-se o estudo das séries temporais de dados de sensoriamento remoto orbital nos espectros óptico e de micro-ondas para a observação de diferentes classes de pastagem na região amazônica, especificamente na porção sul do estado de Roraima. Para tanto, foram utilizadas séries temporais relativas a 2 anos de imagens dos sensores à bordo do Sentinel-1 (SAR - banda C) e Sentinel-2 (MSI).

O uso de séries temporais de imagens no mapeamento de classes de uso e cobertura da terra possibilita que sejam feitas análises além dos padrões espaciais, espectrais e radiométricos dos alvos no espaço geográfico, mas também da forma na qual o valor destes alvos variam ao longo do tempo. Portanto, para alvos dinâmicos como as pastagens, o monitoramento constante por meio da utilização de séries temporais é fundamental, haja vista as questões consonantes ao desmatamento de novas áreas e degradação ambiental. Deste modo, o emprego de séries temporais de imagens para o mapeamento das pastagens é imprescindível, sobretudo em áreas com cobertura frequente de nuvens, como é a região Amazônia.

O processo metodológico de análise consistiu em três etapas macro: Coleta, processamento, classificação e validação dos dados gerados. A etapa de coleta consiste no levantamento dos dados necessários para iniciar o processamento. Dentre as etapas de preparação, cabe destaque para as etapas de teste do filtro de *speckle* que foi aplicado nos dados SAR e na geração dos atributos a serem classificados. Para estas etapas, rotinas automatizadas foram criadas em ambiente de computação em nuvem do *Google Earth Engine*.

A etapa de classificação dos dados foi dividido em três etapas: i) que consistiu na classificação de uso e cobertura da terra objetivando a separação da classe Pastagem das demais que compunham a área de estudo; ii) na estratificação da classe Pastagem em Arbustiva e Herbácea e iii) na geração de indicativos de degradação para as pastagens classificadas. Todas estas etapas foram executadas com a utilização de 3 conjuntos de dados distintos: óptico, radar e a combinação deles (SAR + Óptico).

Baseado no estudo exploratório dos dados e dos atributos derivados das séries temporais, puderam ser observadas as contribuições das variáveis bem como limitações na discriminação das classes de uso e cobertura da terra abordados numa primeira etapa de classificações. As limitações evidenciadas variam desde as características inerentes aos conjuntos de dados até os resultados das classificações, podendo ser

observado o impacto da alta ocorrência de nuvens na região, limitações estas que para os dados obtidos no espectro óptico, pode interferir diretamente na representatividade das métricas temporais, quanto à variação do valor de reflectância ao longo do período, culminando na melhor representação da época seca.

Deste modo, é prudente que o mapeamento das pastagens utilizando apenas dados ópticos tenha um número mínimo de observações válidas para que seja possível representar a variabilidade da pastagem (maior na série temporal) da maneira adequada. Recomenda-se como estudos futuros a avaliação desta quantidade mínima de observações válidas necessárias para representar de maneira adequada a variabilidade das pastagens.

É fato que a limitação dos dados ópticos abre espaço para a inclusão de sensores de micro-ondas em decorrência dos dados adquiridos neste comprimento de onda possuírem menor sensibilidade às nuvens. Desta forma, dentre as características pertinentes ao conjunto de dados de radar destacam-se a regularidade de observações válidas e a sensibilidade da onda neste comprimento de onda com relação a microtopografia, material e conteúdo hídrico dos alvos. Entretanto, as poucas possibilidades de configuração no que diz respeito às polarizações da onda e da necessidade de processamentos adicionais para que haja uma interpretabilidade aprimorada, torna o processo um tanto quanto custoso, além de degradar a resolução original do dado o que pode diminuir sua capacidade discriminativa.

Estas classificações foram executadas em conjuntos de atributos extraídos das séries temporais. Dentre as desvantagens e vantagens de utilizar esta técnica está a redução do volume de dados (diminuição de dados redundantes), no entanto, pode haver perda de detalhes uma vez que uma série temporal passa a não ser representada por todas suas observações, mas sim por estatísticas representativas como a média, desvio-padrão, amplitude entre outros. A distância de Jeffries-Mattusita (JM) foi utilizada como critério de separabilidade para o ranqueamento e seleção dos atributos (descorrelacionados entre si) a serem classificados.

Dentre as métricas utilizadas, salienta-se que as métricas polares obtiveram importância significativa nos cenários de classificação, alcançando valores de *JM* média altos na etapa de seleção de variáveis. Para a classificação na Etapa 1, as variáveis que obtiveram maiores valores de *JM* média (com correlação inferior à 0,6 entre si) foram, no conjunto SAR, a área do primeiro quadrante na representação polar da polarização VV, juntamente com o 25° percentil da polarização VH e o parâmetro de forma do índice RVI; para o conjunto óptico o 10° percentil da banda 12 (infra-

vermelho de ondas curtas), a média da série de NDVI e os valores de máximo da banda 3 (verde) e para o conjunto combinado repetem-se as duas primeiras métricas do óptico, e a última dá lugar ao primeiro quadrante na representação polar da polarização VV.

No resultado da classificação para Etapa 1, a combinação dos dados obteve o melhor desempenho na classificação de uso e cobertura da terra para a área de estudo. Com uma acurácia global de 94,05%, 4 classes foram discriminadas: Pastagem, Formação Florestal, Área Urbana e Corpos D'Água. Neste resultado, a contribuição dos dois conjuntos de dados foi primordial na supressão de ruídos e diminuição na confusão das classes.

Já na separação dos diferentes pastos (Etapa 2), as métricas temporais que obtiveram maiores valores de JM média (com correlação inferior a 0,6 entre si) foram o mínimo na polarização VV, desvio-padrão da polarização VH e o parâmetro de forma da razão cruzada (CR), para o conjunto SAR. Para o conjunto óptico, as métricas que obtiveram maiores valores de JM média nas mesmas condições foram a média da banda do vermelho, a área do 4º quadrante polar do índice CAI e o balanço polar da banda do infravermelho de ondas curtas (banda 12). Já na combinação de dados, repetiu-se a média do vermelho seguido do parâmetro de escala da distribuição Gama para a polarização VH e, por fim, a área do 4º quadrante polar do índice CAI.

Para a Etapa 2 de classificação, os resultados que alcançaram o melhor desempenho foram os obtidos por meio da classificação dos dados ópticos e dos dados combinados, respectivamente. No entanto, por não ter tido diferenças estatisticamente significativas entre os resultados, pode-se afirmar que o conjunto de dados ópticos, que obteve 87,88% de Acurácia Global, é suficiente para discriminar as diferentes pastagens (Herbácea e Arbustiva) dado o custo computacional inferior, uma vez que existam condições mínimas aceitáveis para o seu uso, como a presença de um conjunto de imagens pouco impactado por condicionantes atmosféricas como as nuvens, por exemplo.

Para a geração de indicadores de degradação de pastagens utilizando técnicas de sensoriamento remoto, o NDVI é apresentado na literatura como um intermediário na relação com a qualidade das pastagens indicando o seu estado de degradação. Deste modo, a partir do fatiamento da métrica temporal referente à mediana da série temporal de NDVI, foi possível inferir 4 níveis de degradação das pastagens para a área de estudo (Ausente, Leve, Moderado e Severa) com uma acurácia global de 64%. Esta determinação obteve uma acurácia global de 72%, quando considerou-se

apenas as classes Ausente e Degradado.

No que diz respeito a determinação de indicativos de degradação de pastagens com dados SAR, por não existir nenhum índice ou atributo diretamente relacionado com a degradação de pastagens, optou-se por realizar uma regressão linear múltipla tomando o NDVI utilizando com o conjunto de dados ópticos como referência, obtendo-se $r^2 = 0,6$. O resultado desta regressão, com grande presença de ruídos, após o fatiamento obteve uma acurácia de 43% e 68% quando consideradas quatro e duas classes de degradação, respectivamente.

Por fim, com a utilização da combinação dos resultados oriundos dos melhores cenários, foi possível obter um mapa final de pastagens detalhado para a região de estudo, de modo que fossem representadas as pastagens Arbustivas e Herbáceas bem como seus respectivos indicativos de degradação. Sendo a maior parte das pastagens presentes na área de estudo pertencentes a classe de Pastagens Arbustivas e o maior índice de degradação encontrado em Pastagens Herbáceas.

A implementação desta metodologia de forma operacional é perfeitamente possível, uma vez que rotinas de processamento podem ser automatizadas e o acesso aos dados é gratuito. A operacionalização da geração de indicativos de degradação, baseado na utilização de dados SAR, conforme a metodologia utilizada nesta pesquisa, não é recomendada, uma vez que é dependente de dados ópticos para geração da regressão com $r^2 = 0,6$.

Para trabalhos futuros, recomenda-se o estudo da contribuição de atributos de textura na classificação dos dados. Estes por sua vez podem estar associados (ou não) a técnicas de mineração de dados utilizando segmentos na classificação. A partir de segmentações ou parcelas definidas das pastagens (ex: CAR) das propriedades rurais, pode-se generalizar o status de degradação definindo se a pastagem é arbustiva ou herbácea com base nas ocorrências de *pixels* de cada classe dentro da parcela.

Complementarmente, devido às limitações de resolução espacial presente nos dados trabalhados, a discriminação das pastagens a nível de tipo/espécie fica comprometida, uma vez que não há diferença substancial aparente detectada na escala do dado. No entanto, o estudo dessa possibilidade com dados de sensoriamento remoto hiperespectral ou com dados de maior resolução espacial, são recomendados.

Na utilização de dados de radar para estes fins, recomenda-se também a utilização de filtros de *speckle* que dispõem de técnicas mais simples como o de Mediana,

visto a pequena diferença que pôde ser comprovada nos resultados desta pesquisa com relação a filtros complexos como o de médias não-locais (SDNLM). O uso de atributos derivados da fase das micro-ondas, agregando conceitos da polarimetria e interferometria, também são encorajados visto o potencial de contribuição observado na literatura, além da utilização de diferentes órbitas, polarizações e comprimentos de onda para compor o conjunto de dados.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABDIKAN, S.; SANLI, F. B.; USTUNER, M.; CALÓ, F. Land cover mapping using sentinel-1 sar data. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives**, v. 41, p. 757–761, 2016. ISSN 16821750. 4, 15
- ABDON, M. de M.; LUCIANO, A. C. dos S.; SILVA, J. dos S. V.; OLIVEIRA, M. S. Classificação de pastagens degradadas nos municípios de Corguinho e Rio Negro, MS, utilizando fusão de imagens cbers. **Geografia**, v. 34, p. 709–720, 8 2009. 11
- ALI, I.; CAWKWELL, F.; DWYER, E.; BARRETT, B.; GREEN, S. Satellite remote sensing of grasslands: from observation to management. **Journal of Plant Ecology**, v. 9, p. 649–671, 12 2016. ISSN 1752-9921. Disponível em: <<https://academic.oup.com/jpe/article-lookup/doi/10.1093/jpe/rtw005>>. 11
- ALMEIDA, C. A.; COUTINHO, A. C.; ESQUERDO, J. C. D. M.; ADAMI, M.; VENTURIERI, A.; DINIZ, C. G.; DESSAY, N.; DURIEUX, L.; GOMES, A. R. High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data. **Acta Amazonica**, v. 46, p. 291–302, 9 2016. ISSN 0044-5967. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0044-59672016000300291&lng=en&tlng=en>. 1, 2, 9
- ALMEIDA, C. A.; VALERIANO, D. M.; ESCADA, M. I. S.; RENNÒ, C. D. Estimativa de área de vegetação secundária na Amazônia legal brasileira. **Acta Amazonica**, v. 40, p. 289 – 302, 2010. 44
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. D. M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, p. 711–728, 2013. ISSN 16101227. 26
- ANDRADE, R. G.; LEIVAS, J. F.; GARÇON, E. A. M.; SILVA, G. B. S. da; GOMES, D.; VICENTE, L. E.; BOLFE, É. L.; VICTORIA, D. d. C. Indicativo de degradação de pastagens a partir de dados Spot Vegetation. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu, Paraná. **Anais...** São José dos Campos: INPE, 2013. p. 6917–6922. 12, 46
- ANDRADE, R. G.; RODRIGUES, C. A. G.; SANCHES, I. D.; TORRESAN, F. E.; QUARTAROLI, C. F. Uso de técnicas de sensoriamento remoto na detecção

de processos de degradação de pastagens. **Revista Engenharia na Agricultura** - **REVENG**, v. 21, n. 3, p. 234–243, jun 2013. ISSN 2175-6813. Disponível em: <<https://periodicos.ufv.br/ojs/index.php/reveng/article/view/332>>. 12, 46

BARALDI, A.; PARMIGGIANI, F. A refined gamma map sar speckle filter with improved geometrical adaptivity. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, p. 1245–1257, 1995. 38

BARONA, E.; RAMANKUTTY, N.; HYMAN, G.; COOMES, O. T. The role of pasture and soybean in deforestation of the brazilian Amazon. **Environmental Research Letters**, v. 5, p. 024002, 2010. ISSN 17489326. 1

BARRETT, B.; NITZE, I.; GREEN, S.; CAWKWELL, F. Assessment of multi-temporal, multi-sensor radar and ancillary spatial data for grasslands monitoring in ireland using machine learning approaches. **Remote Sensing of Environment**, v. 152, p. 109–124, 2014. ISSN 00344257. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2014.05.018>>. 4, 14, 20

BELGIU, M.; DRĂGU, L.; DRĂGUȚ, L. Random forest in remote sensing: a review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 4 2016. ISSN 09242716. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0924271616000265>>. 20

BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5–32, 2001. 20, 80

CARNEIRO, A. F.; OLIVEIRA, W. V.; SANT'ANNA, S. J. S.; DOBLAS, J.; VAZ, D. V. Exploiting sentinel-1 sar time series to detect grasslands in the northern brazilian Amazon. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 43, p. 259–265, 2020. Disponível em: <<https://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XLIII-B3-2020/259/2020/>>. 20

CHAGAS, C. S.; VIEIRA, C. A. O.; FERNANDES FILHO, E. I.; CARVALHO JÚNIOR, W. Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 13, p. 319–327, 6 2009. ISSN 1415-4366. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1415-43662009000300014&lng=pt&tlng=pt>. 11

COLEMAN, G.; ANDREWS, H. Image segmentation by clustering. **Proceedings of the IEEE**, v. 67, p. 773–785, 1979. ISSN 0018-9219. 42

DIAS-FILHO, M.; ANDRADE, C. **Pastagens no trópico úmido**. [S.l.]: Embrapa Amazônia Oriental, 2006. 30 p. 3, 7, 103

DIAS-FILHO, M. B. **Degradação de pastagens**. Embrapa, 2017. 19 p. Disponível em: <<http://www.embrapa.br/amazonia-oriental/publicacoes>>. 8

DINIZ, J. M. F. S. **Avaliação do potencial dos dados polarimétricos Sentinel-1A para mapeamento do uso e cobertura da terra na região de Ariquemes - RO**. 132 p. (INPE-18158-TDI/2846). Dissertação (Mestrado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2019. Disponível em: <<http://urlib.net/rep/8JMKD3MGP3W34R/3SL65N8>>. Acesso em: 2020. 4, 15, 18, 20

DINIZ, J. M. F. S.; GAMA, F. F. Utilização da coerência interferométrica SAR para mapeamento do uso e cobertura da terra na região da Amazônia. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., 2019, Santos, Brasil. **Anais...** São José dos Campos: INPE, 2019. p. 263–266. 4, 20

DOBLAS, J.; CARNEIRO, A.; SHIMABUKURO, Y.; SANT'ANNA, S.; ARAGÃO, L. Assessment of rainfall influence on Sentinel-1 time series on amazonian tropical forests aiming deforestation detection improvement. In: IEEE LATIN AMERICAN GRSS ISPRS REMOTE SENSING CONFERENCE, 2020. **Proceedings...** [S.l.]: IEEE, 2020. p. 397–402. 61

DOBLAS, J.; FRERY, A. C.; SANT'ANNA, S. J. S.; CARNEIRO, A.; SHIMABUKURO, Y. E. Assessment of nonlocal means stochastic distances speckle reduction for SAR time series. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2021. **Proceedings...** [S.l.]: IEEE, 2021. p. 3265–3268. 49

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA); INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **TerraClass**. 2020. Disponível em: <<https://www.terraclass.gov.br/>>. Acesso em: 20 maio 2020. 2, 9

EUROPEAN SPACE AGENCY (ESA). **Sentinel-1 user handbook**. 2013. Disponível em: <https://sentinels.copernicus.eu/documents/247904/685163/Sentinel-1_User_Handbook>. Acesso em: 15 jun. 2020. 13, 27

_____. **Sentinel-2 user handbook**. 2015. Disponível em: <https://sentinels.copernicus.eu/documents/247904/685211/Sentinel-2_User_Handbook.pdf/8869acdf-fd84-43ec-ae8c-3e80a436a16c?t=1438278087000>. Acesso em: 15 jun. 2020. 28

FERREIRA, L.; PARENTE, L.; MESQUITA, V.; SANTOS, C. O.; MATOS, A. P. **Pasture appendix**. GO, 2020. 24 p. Disponível em: <https://mapbiomas-br-site.s3.amazonaws.com/Pasture_Appendix_-_ATBD_Collection_5.pdf>. Acesso em: 28 ago. 2020. 83

FERREIRA, L. G.; FERNANDEZ, L. E.; SANO, E. E.; FIELD, C.; SOUSA, S. B.; ARANTES, A. E.; ARAÚJO, F. M. Biophysical properties of cultivated pastures in the brazilian Savanna biome: an analysis in the spatial-temporal domains based on ground and satellite data. **Remote Sensing**, v. 5, p. 307–326, 2013. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/5/1/307>>. 27

FOODY, G. M. Thematic map comparison: evaluating the statistical significance of differences in classification accuracy. **Photogrammetric Engineering and Remote Sensing**, v. 70, p. 627–633, 2004. ISSN 00991112. 45

FROST, V. S.; STILES, J. A.; SHANMUGAN, K. S.; HOLTZMAN, J. C. A model for radar images and its application to adaptive digital filtering of multiplicative noise. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, PAMI-4, p. 157–166, 1982. 38

FUNK, C.; PETERSON, P.; LANDSFELD, M.; PEDREROS, D.; VERDIN, J.; SHUKLA, S.; HUSAK, G.; ROWLAND, J.; HARRISON, L.; HOELL, A.; MICHAELSEN, J. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. **Scientific Data**, v. 2, p. 150066, 12 2015. ISSN 2052-4463. 61

GAO, B. C. NDWI—a normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, Elsevier, v. 58, p. 257–266, 12 1996. ISSN 0034-4257. 39

GOMEZ, L.; OSPINA, R.; FRERY, A. C. Unassisted quantitative evaluation of despeckling filters. **Remote Sensing**, v. 9, p. 389, 2017. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/9/4/389>>. 18, 20, 38

_____. Statistical properties of an unassisted image quality index for sar imagery. **Remote Sensing**, v. 11, p. 385, 2019. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/11/4/385>>. 20

GOODMAN, J. W. Some fundamental properties of speckle. **Journal of the Optical Society of America**, v. 66, p. 1145–1150, 11 1976. Disponível em: <<http://www.osapublishing.org/abstract.cfm?URI=josa-66-11-1145>>. 18

GOOGLE EARTH ENGINE (GEE). **Sentinel-1 algorithms**. 2018. Disponível em: <<https://developers.google.com/earth-engine/sentinel1>>. Acesso em: 20 maio 2020. 27

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 12 2017. ISSN 00344257. Disponível em: <<https://doi.org/10.1016/j.rse.2017.06.031https://linkinghub.elsevier.com/retrieve/pii/S0034425717302900>>. 17

GRAETZ, D. **Grasslands**. [S.l.]: Cambridge University Press, 1991. 125 - 148 p. ISSN 00167398. ISBN 0521470854. 7

HUFFMAN, G.; STOCKER, E.; BOLVIN, E.; NELKIN, J.; GPM, I. F. P. **L3 Half Hourly 0.1 Degree x 0.1 Degree V04**. [S.l.: s.n.], 2015. 61

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Censo Agropecuário 2017: resultados definitivos**. 2019. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/periodicos/3096/agro_2017_resultados_definitivos.pdf>. Acesso em: 20 maio 2019. 1, 7, 9

JAKIMOW, B.; GRIFFITHS, P.; LINDEN, S. van der; HOSTERT, P. Mapping pasture management in the brazilian Amazon from dense Landsat time series. **Remote Sensing of Environment**, v. 205, p. 453–468, 2 2018. ISSN 00344257. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0034425717304728>>. 12, 13

KÖPPEN, W.; GEIGER, R. **Klimate der Erde**. Gotha: verlag Justus Perthes. [S.l.: s.n.], 1928. 91-102 p. 25

KÖRTING, T. S. **Geodma : a toolbox integrating data mining with object-based and multi-temporal analysis of satellite**. 123 p. (INPE-17075-TDI/1936). Tese (Doutorado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2012. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3CCH86S>>. Acesso em: 2020. 21

KÖRTING, T. S.; FONSECA, L. M. G.; CÂMARA, G. Geodma—geographic data mining analyst. **Computers Geosciences**, v. 57, p. 133–145, 8 2013. ISSN 0098-3004. 21, 41

LANDAU, D. P.; BINDER, K. **A guide to Monte Carlo simulations in statistical physics**. [S.l.]: Cambridge University Press, 2009. 540 p. 44

LARY, D. J.; ALAVI, A. H.; GANDOMI, A. H.; WALKER, A. L. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, v. 7, p. 3–10, 1 2016. ISSN 16749871. Disponível em:

<<http://dx.doi.org/10.1016/j.gsf.2015.07.003><https://linkinghub.elsevier.com/retrieve/pii/S1674987115000821>>. 20

LEE, J. S. Refined filtering of image noise using local statistics. **Computer Graphics and Image Processing**, v. 15, p. 380–389, 1981. ISSN 0146-664X.

Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0146664X81800184>>. 38

LEE, J. S.; JURKEVICH, L.; DEWAELE, P.; WAMBACQ, P.; OOSTERLINCK, A. Speckle filtering of synthetic aperture radar images: a review. **Remote Sensing Reviews**, v. 8, p. 313–340, 1994. Disponível em:

<<https://doi.org/10.1080/02757259409532206>>. 18

LEHMANN, E. A.; CACCETTA, P.; LOWELL, K.; MITCHELL, A.; ZHOU, Z. S.; HELD, A.; MILNE, T.; TAPLEY, I. Sar and optical remote sensing: assessment of complementarity and interoperability in the context of a large-scale operational forest monitoring system. **Remote Sensing of Environment**, v. 156, p. 335–348, 2015. ISSN 00344257. 4, 16, 17

LU, D.; LI, G.; MORAN, E.; DUTRA, L.; BATISTELLA, M. A comparison of multisensor integration methods for land cover classification in the Brazilian Amazon. **GIScience Remote Sensing**, v. 48, p. 345–370, 2011. ISSN 1548-1603.

Disponível em: <<https://www.tandfonline.com/doi/full/10.2747/1548-1603.48.3.345>>.

39

MANDAL, D.; KUMAR, V.; RATHA, D.; DEY, S.; BHATTACHARYA, A.; LOPEZ-SANCHEZ, J. M.; MCNAIRN, H.; RAO, Y. S. Dual polarimetric radar vegetation index for crop growth monitoring using Sentinel-1 SAR data. **Remote Sensing of Environment**, v. 247, p. 111954, 9 2020. ISSN 0034-4257. 39

MAPBIOMAS. **Projeto MapBiomass - coleção 4.0 da série anual de mapas de cobertura e uso de solo do Brasil**. 2020. Disponível em:

<<http://mapbiomas.org/>>. Acesso em: 20 maio 2020. 2, 3, 7, 10, 25, 105

MARUJO, R. de F. B.; MOREIRA, M. A.; VOLPATO, M. M. L.; ALVES, H. M. R. Coffee crop detection by automatic classification using spectral and textural attributes and illumination factor. **Coffee Science**, v. 12, p. 164–175, 6 2017.

ISSN 1984-3909. Disponível em: <<http://www.coffeescience.ufla.br/index.php/Coffeescience/article/view/1176>>. 44

MAXWELL, A. E.; WARNER, T. A.; FANG, F. Implementation of machine-learning classification in remote sensing: an applied review.

International Journal of Remote Sensing, v. 39, p. 2784–2817, 5 2018. ISSN 0143-1161. Disponível em:

<<https://doi.org/10.1080/01431161.2018.1433343><https://www.tandfonline.com/doi/full/10.1080/01431161.2018.1433343>>. 20

MCNEMAR, Q. Note on the sampling error of the difference between correlated proportions or percentages. **Psychometrika**, v. 12, p. 153–157, 6 1947. ISSN 0033-3123. 45

NAGLER, P. L.; INOUE, Y.; GLENN, E. P.; RUSS, A. L.; DAUGHTRY, C. S. Cellulose absorption index (CAI) to quantify mixed soil–plant litter scenes.

Remote Sensing of Environment, v. 87, p. 310–325, 10 2003. ISSN 0034-4257. 39, 72

NUMATA, I.; SOARES, J.; BATISTA, G.; ROBERTS, D.; CHADWICK, O.

Evaluation of the conversion from forest to pasture using remote sensing for soil fertility analysis. **International Congress for Photogrammetry and Remote Sensing**, v. 33, p. 1033–1037, 2000. Disponível em:

<http://mtc-m12.sid.inpe.br/attachment.cgi/sid.inpe.br/iris@1912/2005/07.21.01.29.30/doc/2000_numata.pdf>. 8

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, p. 606, 4 2018. ISSN 2072-4292.

Disponível em: <<http://www.mdpi.com/2072-4292/10/4/606>>. 12

PARENTE, L.; FERREIRA, L.; FARIA, A.; NOGUEIRA, S.; ARAÚJO, F.; TEIXEIRA, L.; HAGEN, S. Monitoring the brazilian pasturelands: a new mapping approach based on the Landsat 8 spectral and temporal domains. **International**

Journal of Applied Earth Observation and Geoinformation, v. 62, p. 135–143, 2017. ISSN 1872826X. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2017.06.003>>. 12

PARENTE, L.; MESQUITA, V.; MIZIARA, F.; BAUMANN, L.; FERREIRA, L. Assessing the pasturelands and livestock dynamics in Brazil, from 1985 to 2017: a novel approach based on high spatial resolution imagery and Google Earth Engine cloud computing. **Remote Sensing of Environment**, v. 232, p. 111301, 10 2019. ISSN 00344257. Disponível em: <<https://doi.org/10.1016/j.rse.2019.111301><https://linkinghub.elsevier.com/retrieve/pii/S0034425719303207>>. 2, 12, 20

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V. Scikit-learn. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011. ISSN 23750529. 43

PEREIRA, L. D. O.; FREITAS, C. D. C.; SANT'ANNA, S. J. S.; LU, D.; MORAN, E. F. Optical and radar data integration for land use and land cover mapping in the brazilian Amazon. **GIScience and Remote Sensing**, v. 50, p. 301–321, 2013. ISSN 15481603. 4, 16

PEREIRA, L. O. **Avaliação de métodos de integração de imagens ópticas e de Radar para a classificação do uso e cobertura da terra na Região Amazônica**. 270 p. (INPE-17093-TDI/1952). Dissertação (Mestrado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2012. Disponível em: <<http://urlib.net/ibi/8JMKD3MGP7W/3CHCSD5>>. Acesso em: 2020. 43

PEREIRA, L. O.; FREITAS, C. C.; SANT'ANNA, S. J. S.; REIS, M. S. Evaluation of optical and radar images integration methods for lule classification in Amazon region. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 11, p. 3062–3074, 9 2018. ISSN 1939-1404. Disponível em: <<https://ieeexplore.ieee.org/document/8416958/>>. 4, 16

PERIASAMY, S. Significance of dual polarimetric synthetic aperture radar in biomass retrieval: an attempt on Sentinel-1. **Remote Sensing of Environment**, v. 217, p. 537–549, 11 2018. ISSN 0034-4257. 39

QUEGAN, S.; YU, J. J. Filtering of multichannel sar images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, p. 2373–2379, 2001.

ISSN 01962892. Disponível em:

<<http://ieeexplore.ieee.org/document/964973/>>. 38, 49, 51

RICHARDS, J. A.; JIA, X. **Remote sensing digital image analysis: an introduction**. Springer, 2006. 494 p. Disponível em:

<<https://link.springer.com/book/10.1007%2F3-540-29711-1#about>>. 42

ROUSE, J. W.; HASS, R. H.; SCHELL, J.; DEERING, D. Monitoring vegetation systems in the great plains with ERTS. In: THIRD EARTH RESOURCES TECHNOLOGY SATELLITE (ERTS) SYMPOSIUM. **Proceedings...** [S.l.], 1974. p. 309–317. 12, 39, 70

SANT'ANNA, S. J. S.; MASCARENHAS, N. D. A. Comparação do desempenho de filtros redutores de "speckle". In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador, Brasil. **Proceedings...** São José dos Campos: INPE, 1996. p. 871–877. 18

SICA, F.; PULELLA, A.; NANNINI, M.; PINHEIRO, M.; RIZZOLI, P. Repeat-pass sar interferometry for land cover classification: a methodology using Sentinel-1 short-time-series. **Remote Sensing of Environment**, v. 232, p. 111277, 10 2019. ISSN 00344257. Disponível em:

<<https://doi.org/10.1016/j.rse.2019.111277https://linkinghub.elsevier.com/retrieve/pii/S0034425719302962>>. 20

SILVA, G. B. S.; LOEBMANN, D. G. D. S. W.; FOLHARINI, S. D. O.; NOGUEIRA, S. F.; VICENTE, L. E.; ANDRADE, R. G.; FURTADO, A. L. D. S. **Procedimentos para correção geométrica de imagens de satélite**.

Campinas/SP, 2012. 18 p. Circular técnica 18. Disponível em:

<<https://www.embrapa.br/busca-de-publicacoes/-/publicacao/958866/procedimentos-para-correcao-geometrica-de-imagens-de-satelite>>.

Acesso em: 28 ago. 2020. 42

SOARES, A. R.; BENDINI, H. N.; VAZ, D. V.; UEHARA, T. D. T.; NEVES, A. K.; LECHLER, S.; KÖRTING, T. S.; FONSECA, L. M. G. Stmetrics: a python package for satellite image time-series feature extraction. In: IGARSS 2020 - 2020 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2020. **Proceedings...** [S.l.]: IEEE, 2020. p. 2061–2064. 40

STENDARDI, L.; KARLSEN, S. R.; NIEDRIST, G.; GERDOL, R.; ZEBISCH, M.; ROSSI, M.; NOTARNICOLA, C. Exploiting time series of Sentinel-1 and Sentinel-2 imagery to detect meadow phenology in mountain regions. **Remote**

Sensing, v. 11, p. 542, 3 2019. ISSN 20724292. Disponível em:

<<https://www.mdpi.com/2072-4292/11/5/542>>. 4, 17

TARAVAT, A.; WAGNER, M.; OPPELT, N. Automatic grassland cutting status detection in the context of spatiotemporal Sentinel-1 imagery analysis and artificial neural networks. **Remote Sensing**, v. 11, p. 711, 3 2019. ISSN 2072-4292.

Disponível em: <<https://www.mdpi.com/2072-4292/11/6/711>>. 4, 15

TORRES, L.; CAVALCANTE, T.; FRERY, A. C. Speckle reduction using stochastic distances. **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, v. 7441 LNCS, p. 632–639, 7 2012. Disponível em:

<<https://arxiv.org/abs/1207.0704v1>>. 38

UNIVERSIDADE FEDERAL DE GOIÁS (UFG). **Atlas Digital das Pastagens Brasileiras**. 2021. Disponível em:

<<https://lapig.iesa.ufg.br/p/38972-atlas-das-pastagens>>. Acesso em: 20 maio 2021. 1

VEIGA, J. B. da; TOURRAND, J. F.; PIKETTY, M. G.; POCCARD-CHAPUIS, R.; ALVES, A. M.; THALES, M. C. **Expansão e trajetórias da pecuária na Amazônia: Pará, Brasil**. [s.n.], 2004. 161 p. Disponível em: <9788523007980>.

1

VENTURIERI, A. Apresentação. In: **Degradação de pastagens**. Belém, Pará: EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA),

2017. Disponível em: <<https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1070416/1/TC1117CartilhaPastagemV04.pdf>>. Acesso em: 20 maio 2021. 8

WANG, X.; GE, L.; LI, X. Pasture monitoring using SAR with COSMO-SkyMed, ENVISAT ASAR, and ALOS PALSAR in Otway, Australia. **Remote Sensing**, v. 5, p. 3611–3636, 2013. ISSN 2072-4292. Disponível em:

<<https://www.mdpi.com/2072-4292/5/7/3611>>. 4, 13, 14

WOODHOUSE, I. H. **Introduction to microwave remote sensing**. CRC Press LLC, 2006. 370 p. ISBN 9780415271233. Disponível em:

<<https://www.cabdirect.org/cabdirect/abstract/20063013830>>. 17, 61

XAUD, H. A. M. **Abordagem multisensor aplicada ao monitoramento de florestas tropicais atingidas por incêndios em Roraima**. 153 p.

(INPE-17207-TDI/2044). Tese (Doutorado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2013. Disponível em: <<http://urlib.net/rep/8JMKD3MGP7W/3DRRE8E>>. Acesso em: 2020. 25

YE, Z.-S.; CHEN, N. Closed-form estimators for the gamma distribution derived from likelihood equations. **The American Statistician**, v. 71, p. 177–181, 2017. Disponível em: <<https://doi.org/10.1080/00031305.2016.1209129>>. 22

ZDWG, Z. D. W. G. A pathway to zero deforestation in the brazilian Amazon (executive summary). p. 1–33, 2017. Disponível em: <<https://imazon.org.br/PDFimazon/Ingles/books/APathwaytoZeroDeforestationintheBrazilianAmazon.pdf>>. 1

PUBLICAÇÕES TÉCNICO-CIENTÍFICAS EDITADAS PELO INPE

Teses e Dissertações (TDI)

Teses e Dissertações apresentadas nos Cursos de Pós-Graduação do INPE.

Manuais Técnicos (MAN)

São publicações de caráter técnico que incluem normas, procedimentos, instruções e orientações.

Notas Técnico-Científicas (NTC)

Incluem resultados preliminares de pesquisa, descrição de equipamentos, descrição e ou documentação de programas de computador, descrição de sistemas e experimentos, apresentação de testes, dados, atlas, e documentação de projetos de engenharia.

Relatórios de Pesquisa (RPQ)

Reportam resultados ou progressos de pesquisas tanto de natureza técnica quanto científica, cujo nível seja compatível com o de uma publicação em periódico nacional ou internacional.

Propostas e Relatórios de Projetos (PRP)

São propostas de projetos técnico-científicos e relatórios de acompanhamento de projetos, atividades e convênios.

Publicações Didáticas (PUD)

Incluem apostilas, notas de aula e manuais didáticos.

Publicações Seriadas

São os seriados técnico-científicos: boletins, periódicos, anuários e anais de eventos (simpósios e congressos). Contam destas publicações o Internacional Standard Serial Number (ISSN), que é um código único e definitivo para identificação de títulos de seriados.

Programas de Computador (PDC)

São a seqüência de instruções ou códigos, expressos em uma linguagem de programação compilada ou interpretada, a ser executada por um computador para alcançar um determinado objetivo. Aceitam-se tanto programas fonte quanto os executáveis.

Pré-publicações (PRE)

Todos os artigos publicados em periódicos, anais e como capítulos de livros.