



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”

Faculdade de Ciências e Tecnologia
Campus de Presidente Prudente
Programa de Pós-Graduação em Ciências Cartográficas

ALINE BARROCA MARRA

**CONTRIBUIÇÃO DE IMAGENS SAR NO MONITORAMENTO DE QUEIMADAS NO
PANTANAL MATO-GROSSENSE. ESTUDO DE CASO: PARQUE ESTADUAL
ENCONTRO DAS ÁGUAS**



Presidente Prudente
2025



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
Faculdade de Ciências e Tecnologia
Campus de Presidente Prudente
Programa de Pós-Graduação em Ciências Cartográficas

ALINE BARROCA MARRA

**CONTRIBUIÇÃO DE IMAGENS SAR NO MONITORAMENTO DE QUEIMADAS NO
PANTANAL MATO-GROSSENSE. ESTUDO DE CASO: PARQUE ESTADUAL
ENCONTRO DAS ÁGUAS**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Ciências Cartográficas da Faculdade de Ciências e Tecnologia da Universidade Estadual Paulista “Júlio de Mesquita Filho”, campus de Presidente Prudente.

Orientadora:

Dra. Maria de Lourdes Bueno Trindade Galo

Coorientadores:

Dr. Edson Eyji Sano

Dr. Fabio Giulio Tonolo

Presidente Prudente
2025

M358c Marra, Aline Barroca

Contribuição de imagens SAR no monitoramento de queimadas no Pantanal Mato-grossense. Estudo de caso: Parque Estadual Encontro das Águas / Aline Barroca Marra. -- Presidente Prudente, 2026 197 f.

Tese (doutorado) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências e Tecnologia, Presidente Prudente

Orientadora: Maria de Lourdes Bueno Trindade Galo

Coorientador: Edson Eyji Sano; Fabio Giulio Tonolo

1. C-SAR Sentinel-1. 2. Fogo. 3. Pantanal. 4. Monitoramento. 5. Mapeamento. I. Título.

IMPACTO POTENCIAL DESTA PESQUISA

A pesquisa apresenta uma abordagem metodológica que utiliza imagens SAR para detectar incêndios florestais e monitorar a regeneração da vegetação no período pós-incêndio. O método atende a necessidade de monitoramento contínuo mesmo em condições climáticas adversas e fumaça. Os resultados subsidiam intervenções estratégicas nas áreas impactadas, com foco na proteção e restauração dos ecossistemas terrestres.

POTENTIAL IMPACT OF THIS RESEARCH

The research presents a methodological approach utilizing SAR imagery to detect wildfires and monitor post-fire vegetation regeneration. The method addresses the need for continuous monitoring even under adverse weather conditions and smoke. The results support strategic interventions in impacted areas, with a focus on the protection and restoration of terrestrial ecosystems.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Contribuição de imagens SAR no monitoramento de queimadas no Pantanal Mato-Grossense. Estudo de caso: Parque Estadual Encontro das Águas

AUTORA: ALINE BARROCÁ MARRA

ORIENTADORA: MARIA DE LOURDES BUENO TRINDADE GALO

COORDENADOR: EDSON EYJI SANO

COORDENADOR: FABIO GIULIO TONOLO

Aprovada como parte das exigências para obtenção do Título de Doutora em Ciências Cartográficas, área: Aquisição, Análise e Representação de Informações Espaciais pela Comissão Examinadora:



Profa. Dra. MARIA DE LOURDES BUENO TRINDADE GALO (Participação Presencial)
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente - FCT/Unesp



Profa. Dra. FERNANDA SAYURI YOSHINO WATANABE (Participação Presencial)
Departamento de Cartografia / Universidade Estadual Paulista "Júlio de Mesquita Filho" - Faculdade de Ciências e Tecnologia

**DISPENSA
ASSINATURA**

Prof. Dr. ERIVALDO ANTONIO DA SILVA (Participação Virtual)
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente - FCT/Unesp

**DISPENSA
ASSINATURA**

Prof. Dr. ULISSES SILVA GUIMARÃES (Participação Virtual)
Divisão de Sensoriamento Remoto / Centro Gestor e Operacional do Sistema de Proteção da Amazônia - Censipam



Profa. Dra. NARIANE MARSELHE RIBEIRO BERNARDO DO CARMO (Participação Presencial)
Inspectral

Presidente Prudente, 10 de julho de 2025

Dedicatória

Dedico este trabalho à Deus e à minha família!

Agradecimentos

Agradeço primeiramente à Deus, e às pessoas que caminharam comigo e colaboraram para o meu crescimento pessoal, profissional e acadêmico durante esta jornada de tantos aprendizados.

Agradeço imensamente à minha família, minha mãe Neuza, meu pai Iderval e minhas irmãs Daniele, Soellyn e Luana, pelo amor, carinho e apoio incondicional, e por entenderem a minha ausência em alguns momentos diante da oportunidade da realização do meu doutorado e de etapas desafiadoras na minha vida. Sempre estiveram ao meu lado, tendo muita paciência, me apoiando nos momentos difíceis, comemorando minhas conquistas e dando o suporte necessário.

Agradeço à minha orientadora, Profa. Dra. Maria de Lourdes, que acreditou em mim, e me ofereceu a oportunidade de conquistar um sonho. Ao meu coorientador Dr. Edson Eyji Sano e ao Dr. Fabio Giulio Tonolo, coorientador e supervisor durante meu doutorado sanduíche no *Laboratory of Geomatics for Cultural Heritage (G4CH)*, do Politécnico de Torino (PoliTo), em Turim, Itália.

À minha amiga da Unesp/PPGCC Viviane, e aos amigos do Instituto Geográfico e Cartográfico (IGC), obrigada pelo apoio na reta final do doutorado.

Ao Programa de Pós-Graduação em Ciências Cartográficas (PPGCC) e à Universidade Estadual Paulista (UNESP) pela infraestrutura fornecida.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001 e do Programa Institucional de Internacionalização (Capes-PrInt - Processo 88887.716750/2022-00).

RESUMO

O Pantanal Mato-Grossense, reconhecido por sua extensa planície de inundação e pela sua biodiversidade, vem enfrentando um aumento expressivo na frequência e intensidade de queimadas, agravadas por alterações climáticas. Esses eventos têm gerado impactos significativos sobre o uso e a cobertura da terra, especialmente em áreas protegidas. Diante desse cenário, o monitoramento do fogo, de seus efeitos ecológicos e dos processos de regeneração da vegetação torna-se essencial para a conservação da biodiversidade. Esta pesquisa se propõe a investigar a contribuição de atributos extraídos de dados C-SAR Sentinel-1 na detecção e mapeamento de áreas queimadas, assim como no monitoramento dos impactos das queimadas em diferentes tipologias de vegetação do Pantanal. Adotando o Parque Estadual Encontro das Águas como área de estudo, foi desenvolvida uma abordagem metodológica que avalia, inicialmente, o potencial de atributos polarimétricos extraídos de dados SAR na detecção de áreas queimadas, comparando com abordagens consolidadas que usam índices espectrais derivados do sensor óptico MSI/Sentinel-2. Nesse sentido, imagens pré e pós-fogo dos coeficientes de retroespalhamento SAR σ_{VH}^0 e σ_{VV}^0 foram comparadas ao índice espectral *Normalized Burn Ratio* (NBR) por meio do algoritmo *Random Forest* (RF), e uma rede neural de segmentação semântica U-Net foi empregada na classificação de conjuntos de dados distintos: puramente atributos SAR e misto (SAR e NBR). Em ambos os casos, o desempenho dos atributos SAR foi similar ao do índice NBR. Posteriormente, foi analisado o desempenho de diferentes algoritmos baseados em Aprendizado de Máquina (RF, KNN, SVM e CART) no mapeamento de áreas queimadas exclusivamente a partir de dados SAR, resultando em um melhor desempenho para o algoritmo RF. Por fim, foram construídas séries temporais dos atributos SAR mais relevantes, dos índices espectrais NDVI e NBR e variáveis meteorológicas (precipitação e temperatura), abrangendo o período de 2019 a 2024, definido com base na disponibilidade conjunta dos dados utilizados. A análise do comportamento temporal das diferentes tipologias florestais indicou que os atributos SAR se mostraram sensíveis às alterações estruturais da vegetação causadas pelo fogo e permitiu identificar rupturas no perfil temporal associadas a eventos climáticos extremos, revelando padrões sazonais e dinâmicas de regeneração. Os coeficientes de retroespalhamento σ_{VH}^0 e σ_{VV}^0 evidenciaram comportamento similar ao índice óptico NBR, amplamente utilizado na detecção de áreas queimadas. Ressalta-se, especialmente, o σ_{VH}^0 , cuja maior sensibilidade a alterações na estrutura da vegetação o torna particularmente eficiente na detecção de impactos mais severos. Observou-se maior resiliência em formações campestres e impacto prolongado em florestas e savanas, especialmente após os incêndios severos de 2020. Os resultados obtidos na pesquisa reforçam a viabilidade do uso de dados SAR no monitoramento ambiental contínuo, mesmo em condições atmosféricas adversas. A integração de sensores e o uso de técnicas avançadas de análise constituem uma estratégia eficaz para apoiar políticas públicas de conservação, prevenção de incêndios e gestão adaptativa de ecossistemas dinâmicos como o Pantanal.

Palavras-chave: Pantanal, fogo, C-SAR Sentinel-1, monitoramento, mapeamento, Unidade de Conservação.

ABSTRACT

The Pantanal of Mato Grosso, known for its vast floodplain and rich biodiversity, has been facing a significant increase in the frequency and intensity of wildfires, exacerbated by climate change. These events have caused considerable impacts on land use and land cover, especially within protected areas. Given this scenario, monitoring fire, its ecological effects, and vegetation regeneration processes becomes essential for biodiversity conservation. This research aims to investigate the contribution of attributes extracted from Sentinel-1 C-SAR data in detecting and mapping burned areas, as well as in monitoring the impacts of wildfires on different vegetation types in the Pantanal. By adopting the Encontro das Águas State Park as the study area, a methodological approach was developed to initially assess the potential of polarimetric attributes extracted from SAR data in detecting burned areas, comparing them to well-established approaches using spectral indices derived from the MSI/Sentinel-2 optical sensor. In this context, pre- and post-fire SAR backscatter coefficients σ_{VH}^0 and σ_{VV}^0 were compared to the Normalized Burn Ratio (NBR) spectral index using the Random Forest (RF) algorithm, and a U-Net semantic segmentation neural network was applied to classify different datasets: purely SAR attributes and a mixed dataset (SAR and NBR). In both cases, the performance of the SAR attributes was comparable to that of the NBR index. Subsequently, the performance of different Machine Learning algorithms (RF, KNN, SVM, and CART) in mapping burned areas using SAR data exclusively was evaluated, with RF yielding the best results. Finally, time series were constructed for the most relevant SAR attributes, NDVI and NBR spectral indices, and meteorological variables (precipitation and temperature), covering the years from 2019 to 2024, according to the common period of data availability. The temporal analysis of different forest typologies revealed that SAR attributes are sensitive to structural changes in vegetation caused by fire, allowing the identification of temporal profile disruptions associated with extreme climatic events, and revealing seasonal patterns and regeneration dynamics. The SAR backscatter coefficients σ_{VH}^0 and σ_{VV}^0 showed similar behavior to the NBR optical index, which is widely used for detecting burned areas. Notably, σ_{VH}^0 demonstrated greater sensitivity to changes in vegetation structure, making it particularly effective in detecting more severe impacts. Grassland formations showed greater resilience, while forests and savannas experienced prolonged impacts, especially following the severe fires of 2020. The findings of this study reinforce the feasibility of using SAR data for continuous environmental monitoring, even under adverse atmospheric conditions. The integration of sensors and the application of advanced analysis techniques represent an effective strategy to support public policies for conservation, fire prevention, and adaptive management of dynamic ecosystems such as the Pantanal.

Keywords: Pantanal, fire, C-SAR Sentinel-1, monitoring, mapping, Conservation Unit.

LISTA DE FIGURAS

Figura 1 - Localização da Bacia do Alto Paraguai (BAP) no Brasil, destacando os principais rios e sua distribuição nos biomas Pantanal, Cerrado e Amazônia.	16
Figura 2 - Área alagada no Pantanal em três anos da série histórica da Coleção 9 do MapBiomas (1988, 2018 e 2023), representando em azul, regiões que ficaram alagadas ao menos uma vez ao longo do ano.	20
Figura 3 - Curva de reflectância típica de uma folha verde.	23
Figura 4 - Curvas de resposta espectral da vegetação sadia (linha verde) e da vegetação queimada (linha vermelha), ao longo do espectro eletromagnético.	26
Figura 5 - Funcionamento básico de um Radar.	31
Figura 6 - Geometria de visualização lateral de sistemas de imageamento por Radar. .	32
Figura 7 - Elementos geométricos da configuração de imageamento por Radar.	33
Figura 8 - Geometria <i>Slant Range</i> (alcance inclinado)	34
Figura 9 - Diferença entre as geometrias de imageamento em <i>Slant Range</i> e <i>Ground Range</i>	35
Figura 10 - Efeitos causados pelo deslocamento do relevo e pela presença de sombras em imagens de Radar: (a) relação entre o <i>range</i> (alcance) do terreno e o ângulo de incidência; (b) interação entre a inclinação do terreno e a frente de onda da radiação incidente, influenciando a ordem dos sinais refletidos; (c) aparência da imagem resultante, com destaque para o efeito mais severo de <i>layover</i> em <i>near range</i> e <i>foreshortening</i> mais suave em <i>far range</i> ; e (d) aumento do comprimento das sombras conforme cresce o ângulo de incidência, evidenciando sua dependência da topografia e da geometria de aquisição.	36
Figura 11 - Variação da rugosidade da superfície em função da reflexão de Radar de banda X e banda L.	38
Figura 12 - Orientação espacial dos vetores campo elétrico e campo magnético.	39
Figura 13 - Comprimento de onda, frequência e amplitude de uma onda eletromagnética.	39
Figura 14 - Exemplo do cálculo da resolução em <i>range</i>	42
Figura 15 - Dependência da resolução azimutal em função das distâncias SR (<i>near</i> e <i>far range</i>) medidas no plano inclinado.	43
Figura 16 - Variação do ângulo de incidência em função da topografia da região imageada.	44
Figura 17 - Espalhamentos superficial e volumétrico numa hipotética floresta.	46
Figura 18 - Exemplo de contribuição dos espalhamentos superficial e volumétrico em uma floresta para a energia de micro-ondas nas bandas X, C e L.	46
Figura 19 - Efeito do <i>double-bounce</i> em (a) diedro, (b) triedro e em (c) alvos naturais (árvore) e antrópicos (prédio).	48
Figura 20 - Formação do <i>speckle</i> em imagem de Radar onde (a) ilustra uma interferência construtiva, (b) interferência negativa e (c) o efeito dessas interferências em uma célula de resolução.	50

Figura 21 - Técnicas utilizadas para redução do <i>speckle</i> na imagem de Radar em que (a) se refere ao processamento <i>multilooking</i> dividido em 5 <i>looks</i> e (b) filtragem espacial numa janela de tamanho 3x3.	51
Figura 22 - Representação dos planos de normalização utilizados na calibração radiométrica das imagens de Radar: <i>Ground Range</i> (σ_0), <i>Slant Range</i> (β_0) e plano perpendicular ao <i>Slant Range</i> (γ^0).	53
Figura 23 - Exemplo de mecanismos dominantes de retroespalhamento de Radar nas bandas C/L, em que (a) se refere ao espalhamento volumétrico antes de um incêndio e (b) ao espalhamento superficial de terreno após um incêndio.	58
Figura 24 - Estrutura da rede neural convolucional U-Net.	63
Figura 25 - Sequência de imagens de satélite organizadas ao longo do tempo, formando uma série temporal para um determinado pixel. A linha do tempo representa os valores do índice espectral NDVI, permitindo acompanhar variações na vegetação no intervalo de 2000 a 2016.....	66
Figura 26 - Componentes ajustados de sazonalidade e tendência para uma série temporal do índice NDVI a partir de imagens MODIS com intervalo de 16 dias, correspondentes a uma plantação de pinheiros no sudeste da Austrália. A componente de erro foi ocultada e não será analisada neste estudo.	68
Figura 27 - Aplicação do BFAST a uma série temporal do atributo PA na classe FS, ilustrando a identificação de um ponto de quebra (linha tracejada vertical em T_t), e os valores de tendência (β) e p-valor estimados para cada segmento.	70
Figura 28 - Mapa de localização do Parque Estadual Encontro das Águas (PEEA), situado no sul do estado de Mato Grosso, entre os municípios de Poconé e Barão de Melgaço, no bioma Pantanal. À esquerda, o detalhamento da área do parque é apresentado com base nos dados SRTM, indicando os diferentes níveis de declividade na região, conforme classificação definida pela Embrapa (1979).	74
Figura 29 - Distribuição espacial dos focos de queimadas no PEEA ao longo de 2020, discriminados por mês, considerando apenas os meses com registros, conforme dados do Programa Queimadas do INPE.....	76
Figura 30 - Imagens ópticas do PEEA do sensor Sentinel-2, pré e pós-fogo (20 de julho e 22 de novembro de 2020, respectivamente), em composição colorida verdadeira (R4G3B2).	76
Figura 31 - Distribuição espacial dos focos de queimadas no PEEA nos anos de 2023 e 2024, discriminados por mês de ocorrência, conforme dados do Programa Queimadas do INPE.	77
Figura 32 - Distribuição espacial dos tipos de uso e cobertura da terra no bioma Pantanal em 2020, conforme dados da Coleção Beta 10 metros do MapBiomias.	83
Figura 33 - Mapa de uso e cobertura da terra do PEEA para o ano de 2020, conforme a Coleção Beta 10 metros do Projeto MapBiomias.....	85
Figura 34 - Distribuição espacial das áreas queimadas no PEEA, separadas por meses de registro (agosto, setembro, outubro e novembro) em 2020, conforme o Monitor do Fogo.	88
Figura 35 - Localização da estação pluviométrica Ilha Camargo de responsabilidade da ANA, operada por SGB-CPRM, em relação à área de estudo.	90

Figura 36 - Etapas de pré-processamento de imagens SAR/Sentinel-1 SLC e GRD.....	97
Figura 37 - Fluxograma geral da metodologia aplicada no experimento, onde $NBR_{pré}$ e $NBR_{pós}$ se referem ao índice espectral óptico Normalized Burn Ratio pré e pós-fogo, respectivamente, $dNBR$ se refere à diferença entre os NBRs pré e pós fogo, e dVV e dVH às diferenças pré e pós-fogo de σ_{VV0} e σ_{VH0} , respectivamente.	101
Figura 38 - Fluxograma geral da metodologia aplicada no experimento, em que PA se refere ao índice polarimétrico <i>Polarization Averaging</i> , NBR e NDWI aos índices espectrais ópticos <i>Normalized Burn Ratio</i> e <i>Normalized Difference Water Index</i> , respectivamente; e $dNBR$ à diferença entre os NBRs pré e pós-fogo. Focos de calor INPE correspondem a pontos detectados via satélite que indicam áreas com altas temperaturas, geralmente associadas a queimadas.....	103
Figura 39 – Área incluindo parte do PEEA utilizada na detecção de áreas queimadas com aplicação da rede de segmentação semântica U-Net, sobre imagem de fundo Sentinel-2 (composição colorida verdadeira), adquirida em 20 de julho de 2020, com o limite do parque destacado em amarelo.....	104
Figura 40 - Fluxograma geral da metodologia aplicada neste experimento.....	107
Figura 41 - Máscara d'água do PEEA gerada para processamento dos dados, em que a) mostra a extração de corpos d'água dos tipos de uso e cobertura do solo do Projeto Mapbiomas – Coleção Beta, referente ao ano de 2020, e b) os tipos de uso e cobertura do solo após a aplicação da máscara.	108
Figura 42 - Distribuição espacial das amostras coletadas na área de estudo, em que os polígonos em vermelho se referem às áreas queimadas e em preto, às áreas não queimadas. O uso e cobertura do solo corresponde ao mapeamento do MapBiomias, Coleção Beta (ano de 2020).....	109
Figura 43 - Metodologia geral aplicada na geração das series temporais de dados SAR e ópticos. FF se refere à Formação Florestal, FS à Formação Savânica, CAAP à Campo Alagado e Área Pantanosa, FC à Formação Campestre e P à Pastagem.	111
Figura 44 - Classificação das diferenças a) $dNBR$, b) dVH e c) dVV , onde as áreas queimadas estão representadas em vermelho e as não queimadas, em verde.	118
Figura 45 - Mapas temáticos resultantes da comparação individual entre a classificação de a) $dNBR$ com dVH e b) $dNBR$ com dVV . A cor azul representa áreas não queimadas em dVH e dVV e queimadas em $dNBR$; a cor magenta, áreas queimadas em dVH e dVV e não queimadas em $dNBR$; e a branca, áreas coincidentes.....	120
Figura 46 - Dispersão espacial das áreas queimadas obtidas por meio de: (a) anotações geradas de forma semiautomática, a partir de limiar de alta severidade de fogo, máscara de água e filtro Sieve aplicados ao $dNBR$; (b) predição resultante da aplicação da rede U-Net aos conjuntos de dados ópticos/SAR e; (c) predição da U-Net com base em imagens SAR. Áreas indicadas em vermelho representam as queimadas.	122
Figura 47 - Curvas de Perda e Acurácia resultantes dos dados de treinamento e validação para (a e c) o conjunto de dados ópticos/SAR e (b e d) para o conjunto de dados SAR.	123
Figura 48 - Imagens SAR diferença temporal dos atributos VV e VH e dos índices polarimétricos CR, RVI, DPSVI, NRPB, DPDD e PA. Os atributos foram extraídos das diferenças entre imagens SAR tomadas em 27 de julho (pré-fogo) e 24 de novembro de 2020 (pós-fogo).	125

Figura 49 - Áreas queimadas por tipo de uso e cobertura do solo e por mês, geradas a partir da intersecção dos produtos do Projeto MapBiomias, referentes ao ano de 2020: tipos de uso e cobertura do solo da Coleção Beta e dados de áreas queimadas do Monitor do Fogo. FF se refere à Formação Florestal, FS à Formação Savânica, CAAP à Campo Alagado e Área Pantanosa, FC à Formação Campestre e P à Pastagem.	128
Figura 50 - Área total queimada obtida a partir do modelo RF no PEEA, destacada em vermelho.	130
Figura 51 - Área queimada resultante da aplicação do modelo RF por tipo de uso e cobertura do solo, obtida por meio da intersecção com dados do Projeto Mapbiomas – Coleção Beta. FF se refere à Formação Florestal, FS à Formação Savânica, CAAP à Campo Alagado e Área Pantanosa, FC à Formação Campestre e P à Pastagem.	130
Figura 52 - Média dos valores dos pixels referentes às amostras de áreas queimadas e não queimadas, representadas em triângulo vermelho e círculo verde, respectivamente, para σ_{VH0} e σ_{VV0} e índices polarimétricos CR, RVI, DPSVI, NRPB, DPDD e PA. Os valores foram extraídos a partir de uma imagem SAR adquirida em 24 de novembro de 2020, posterior ao evento de fogo.	132
Figura 53 - Distribuição espacial das áreas queimadas no PEEA entre 2019 e 2024, com base nos dados do Projeto MapBiomias – Monitor do Fogo.	134
Figura 54 - Perfis temporais da média (a) e do desvio padrão (b) mensais do índice espectral óptico NDVI.	135
Figura 55 - Perfis temporais da média (a) e do desvio padrão (b) mensais do índice espectral óptico NBR.	135
Figura 56 - Perfis temporais da média (a) e do desvio padrão (b) mensais do coeficiente de retroespalhamento SAR σ_{VH0}	138
Figura 57 - Perfis temporais da média (a) e do desvio padrão (b) mensais do coeficiente de retroespalhamento SAR σ_{VV0}	138
Figura 58 - Perfis temporais da média (a) e do desvio padrão (b) mensais do índice polarimétrico SAR PA.	139
Figura 59 - Perfis temporais da média (a) e do desvio padrão (b) mensais do índice polarimétrico SAR DPDD.	139
Figura 60 - Séries temporais dos atributos ópticos NDVI (a, b) e NBR (c, d) geradas para as classes FC e FS, bem como suas respectivas decomposições obtidas pelo algoritmo BFAST.	147
Figura 61 - Séries temporais dos coeficientes de retroespalhamento SAR σ_{VH0} (a, b) e σ_{VV0} (c, d) geradas para as classes FC e FS, bem como suas respectivas decomposições obtidas pelo algoritmo BFAST.	150
Figura 62 - Séries temporais dos atributos polarimétricos SAR PA (a, b) e DPDD (c, d) geradas para as classes FC e FS, bem como suas respectivas decomposições obtidas pelo algoritmo BFAST.	154

LISTA DE TABELAS

Tabela 1 - Formulação dos índices espectrais NDVI, NBR e NDWI. NIR (<i>Near Infrared</i>) se refere ao infravermelho próximo e SWIR (<i>Shortwave Infrared</i>) ao infravermelho de ondas curtas.	27
Tabela 2 - Principais bandas utilizadas pelos sensores de Radar e seus respectivos intervalos aproximados de comprimentos de onda e de frequência.	29
Tabela 3 - Formulação de índices polarimétricos em que σ_{VV0} e σ_{HH0} se referem aos coeficientes de retroespalhamento da energia de Radar nas polarizações paralelas VV e HH, e σ_{VH0} e σ_{HV0} aos coeficientes de retroespalhamento nas polarizações cruzadas VH e HV, respectivamente.	54
Tabela 4 - Bandas espectrais do Sentinel-2 e suas respectivas resoluções espaciais, número, nome e comprimentos de onda centrais.	81
Tabela 5 - Desempenho dos modelos de RF na detecção de áreas queimadas nas imagens dNBR, dVH e dVV, referente aos 30% de dados de validação.	119
Tabela 6 – Áreas classificadas como queimadas (em hectares), valores de IoU e tempo de processamento resultantes da aplicação da rede U-Net nos dois conjuntos de dados..	124
Tabela 7 - Métricas de acurácia resultantes das classificações dos algoritmos baseados em ML testados. Cl. refere-se ao resultado da classificação e Ref. é a referência.	126
Tabela 8 - <i>Ranking</i> de importância dos atributos extraído do algoritmo RF na classificação das áreas queimadas e não queimadas, baseado nos dados de validação.	127
Tabela 9 - IoU e área total classificada como queimada referente aos algoritmos ML testados.	128
Tabela 10 - Valores médios dos pixels referentes às amostras de áreas queimadas e não queimadas, dos coeficientes de retroespalhamento σ_{VH0} e σ_{VV0} e índices polarimétricos CR, RVI, DPSVI, NRPB, DPDD e PA. As médias foram extraídas a partir da imagem SAR adquirida em 24 de novembro de 2020, posterior ao evento de fogo.	132
Tabela 11 – Coeficientes de correlação de Pearson entre os índices espectrais NBR e NDVI e os atributos SAR (σ_{VV0} , σ_{VH0} , PA e DPDD), calculados separadamente para cada classe de uso e cobertura do solo do PEEA.	145

LISTA DE QUADROS

Quadro 1 - Descrição detalhada dos tipos de uso e cobertura da terra da Coleção 7.1 do MapBiomias (à que se refere a coleção BETA – 10 m) para o PEEA inserido no bioma Pantanal.	84
Quadro 2 - Fotografias referentes às classes de uso e cobertura no PEEA, conforme a Chave de Interpretação Visual do Laboratório de Processamento de Imagens e Geoprocessamento - LAPIG (LAPIG, 2025).	86
Quadro 3 - Síntese dos procedimentos gerais adotados em função dos objetivos específicos.	96
Quadro 4 - Datas de aquisição das imagens SAR do sensor Sentinel-1A empregadas na composição das séries temporais mensais. As cenas foram adquiridas entre janeiro de 2019 e dezembro de 2024. A alternância entre células cinza agrupa visualmente a divisão das aquisições por mês ao longo das séries temporais.	112
Quadro 5 - Datas de aquisição das imagens do sensor Sentinel-2 (satélites S2A e S2B) empregadas na composição das séries temporais mensais. As cenas foram adquiridas entre janeiro de 2019 e dezembro de 2024 e filtradas para cobertura de nuvens máxima de 30%. A alternância entre células cinza agrupa visualmente a divisão das aquisições por mês ao longo das séries temporais. As células destacadas em laranja indicam meses com falhas ou ausência de imagens ópticas devido à elevada cobertura de nuvens.	114

LISTA DE SIGLAS

AG	Acurácia Global
ANA	Agência Nacional de Águas
BAP	Bacia do Alto Paraguai
BFAST	<i>Breaks For Additive Seasonal and Trend</i>
CAAP	Campo Alagado e Área Pantanosa
CART	<i>Classification and Regression Trees</i>
CR	<i>Cross Ratio</i> (ou <i>Cross Polarization Ratio</i>)
DL	<i>Deep Learning</i>
DPDD	<i>Dual-pol Diagonal Distance</i>
DPSVI	<i>Dual-Polarized SAR Vegetation Index</i>
dCR	Diferença do índice CR (pré e pós-fogo)
dDPDD	Diferença do índice DPDD (pré e pós-fogo)
dDPSVI	Diferença do índice DPSVI (pré e pós-fogo)
dNBR	Diferença do índice NBR (pré e pós-fogo)
dPA	Diferença do índice PA (pré e pós-fogo)
dRVI	Diferença do índice RVI (pré e pós-fogo)
dVH	Diferença do coeficiente VH (pré e pós-fogo)
dVV	Diferença do coeficiente VV (pré e pós-fogo)
ESA	<i>European Space Agency</i>
FC	Formação Campestre
FF	Formação Florestal
FS	Formação Savânica
GEE	<i>Google Earth Engine</i>
GRD	<i>Ground Range Detected</i>
HV	Horizontal-Vertical (polarização cruzada)
HH	Horizontal-Horizontal (polarização paralela)
InSAR	<i>Interferometric Synthetic Aperture Radar</i>
IoU	<i>Intersection over Union</i>
IPCC	<i>Intergovernmental Panel on Climate Change</i>
IW	<i>Interferometric Wide Swath Mode</i>
KNN	<i>K-Nearest Neighbors</i>

ML	<i>Machine Learning</i>
MLPN	<i>Multi-Layer Perceptron Network</i>
MSI	<i>Multispectral Instrument</i>
NBR	<i>Normalized Burn Ratio</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NDWI	<i>Normalized Difference Water Index</i>
NIR	<i>Near Infrared</i>
NRPB	<i>Normalized Ratio Procedure between Bands</i>
P	<i>Pastagem</i>
PA	<i>Polarization Averaging</i>
PEEA	<i>Parque Estadual Encontro das Águas</i>
PolSAR	<i>Polarimetric Synthetic Aperture Radar</i>
PolInSAR	<i>Polarimetric Interferometric Synthetic Aperture Radar</i>
Radar	<i>Radio Detection and Ranging</i>
RAR	<i>Real Aperture Radar</i>
REM	<i>Radiação Eletromagnética</i>
RF	<i>Random Forest</i>
RLO	<i>Rio, Lago ou Oceano</i>
RVI	<i>Radar Vegetation Index</i>
SAR	<i>Synthetic Aperture Radar</i>
SLC	<i>Single Look Complex</i>
SNAP	<i>Sentinel Application Platform</i>
SRTM	<i>Shuttle Radar Topography Mission</i>
SVM	<i>Support Vector Machine</i>
SWIR	<i>Shortwave InfraRed</i>
TOPSAR	<i>Terrain Observation with Progressive Scans SAR</i>
UC	<i>Unidade de Conservação</i>
VH	<i>Vertical-Horizontal (polarização cruzada)</i>
VV	<i>Vertical-Vertical (polarização paralela)</i>
WWF	<i>World Wide Fund for Nature</i>

SUMÁRIO

1. INTRODUÇÃO	1
1.1 Apresentação do problema.....	2
1.2 Hipótese e objetivos.....	5
2. RELEVÂNCIA DA PESQUISA E ESTADO DA ARTE	7
3. FUNDAMENTAÇÃO TEÓRICA	14
3.1 Bioma Pantanal	14
3.1.1 Caracterização do bioma Pantanal	14
3.1.2 Caracterização das Unidades de Conservação do Pantanal	17
3.1.3 Transformação do uso e cobertura da terra no Pantanal	19
3.2 Sensoriamento Remoto óptico	22
3.2.1 Comportamento espectral da vegetação	22
3.2.2 Sensoriamento Remoto óptico na vegetação submetida ao fogo	24
3.3 Sensoriamento Remoto por micro-ondas.....	28
3.3.1 Princípios de funcionamento do SAR	30
3.3.2 Geometria de aquisição de dados do sistema SAR	32
3.3.3 Fatores que influenciam a resposta do Radar.....	37
3.3.4 Ruído <i>Speckle</i> na imagem de Radar.....	49
3.3.5 Calibração radiométrica	52
3.3.6 Atributos Polarimétricos SAR.....	53
3.3.7 Sensoriamento Remoto SAR da vegetação	56
3.4 Algoritmos de classificação de imagens baseados em aprendizado de máquina..	59
3.5 Séries temporais de atributos extraídos de imagens	64
4. MATERIAIS E MÉTODOS.....	73
4.1 Especificação da área de estudos	73
4.2 Área de Estudos: Parque Estadual Encontro das Águas	73
4.3 Materiais	77
4.3.1 Imagens SAR/Sentinel-1	77
4.3.2 Imagens multiespectrais ópticas Sentinel-2	80
4.3.3 Dados do Projeto MapBiomias.....	82
4.3.3.1 Mapbiomas Coleção BETA.....	82
4.3.3.2 MapBiomias Monitor do Fogo	86
4.3.4 Dados meteorológicos	89
4.3.4.1 Precipitação	89

4.3.4.2 Temperatura.....	90
4.3.5 Ferramentas Computacionais	92
4.4 Metodologia	96
4.4.1 Pré-processamento das imagens SAR e ópticas e geração de índices polarimétricos e espectrais	97
4.4.2 Análise do potencial dos atributos SAR na detecção de áreas queimadas...	100
4.4.3 Detecção de áreas queimadas em imagens SAR por meio de segmentação semântica	102
4.4.4 Mapeamento de áreas queimadas por tipo de cobertura da terra, a partir de imagens SAR de 2020	106
4.4.5 Construção e análise de séries temporais de atributos polarimétricos SAR	110
5. RESULTADOS.....	118
5.1 Potencial dos atributos SAR/Sentinel-1 no mapeamento de áreas queimadas do PEEA	118
5.2 Áreas queimadas do PEEA detectadas pela segmentação semântica de atributos SAR.....	121
5.3 Impacto das queimadas de 2020 sobre os tipos de uso e cobertura da terra do PEEA a partir de imagens SAR	124
5.4 Evolução da vegetação natural nas áreas queimadas do PEEA por meio de atributos polarimétricos SAR.....	131
5.4.1 Análise de séries temporais dos índices ópticos NDVI e NBR e SAR σ_{VH0} , σ_{VV0} , DPDD e PA	133
5.4.2 Análise das correlações entre índices ópticos e parâmetros SAR.....	144
5.4.3 Análise de tendência, sazonalidade e identificação de quebras nas séries temporais por meio do modelo BFAST	146
6. CONCLUSÃO E RECOMENDAÇÕES	157
REFERÊNCIAS	161
DADOS CURRICULARES.....	177

1. INTRODUÇÃO

A variabilidade climática é um fenômeno natural que ocorre ao longo da história do planeta. No entanto, nas últimas décadas as mudanças climáticas têm se intensificado significativamente, impulsionadas principalmente por fatores antrópicos. O Sexto Relatório de Avaliação do Painel Intergovernamental sobre Mudanças Climáticas (*Intergovernmental Panel on Climate Change - IPCC*), publicado em 2023 (IPCC, 2023), destaca que o aquecimento global já atingiu aproximadamente 1,1°C acima da média da temperatura da superfície global do período de 1850 a 1900, provocando impactos adversos generalizados.

O relatório destaca ainda que, com o agravamento contínuo do aquecimento global, a frequência e a intensidade de eventos climáticos extremos, como ondas de calor, secas e incêndios florestais, tendem a aumentar, afetando negativamente a segurança alimentar, a disponibilidade de água e a biodiversidade. No contexto brasileiro, as mudanças no uso da terra, especialmente o desmatamento e as queimadas, são responsáveis por uma parcela expressiva das emissões de gases de efeito estufa. De acordo com Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa (SEEG, 2025) do Observatório do Clima, em 2022 o setor de uso da terra e florestas representou aproximadamente 47% das emissões brutas do país. A remoção da vegetação nativa não apenas contribui para o aquecimento global, mas também resulta na perda de biodiversidade e degradação dos ecossistemas.

O agravamento contínuo do aquecimento global representa uma ameaça direta a ecossistemas sensíveis, como o Pantanal, localizado na região Centro-Oeste do Brasil e se estendendo também por partes da Bolívia e do Paraguai. Reconhecido como a maior planície de inundação do planeta e um dos biomas mais ricos em biodiversidade, o Pantanal possui características únicas de alternância entre períodos de cheia e seca, funcionando como um sistema altamente dinâmico e interdependente de ciclos hidrológicos e processos ecológicos naturais. No entanto, desde 2019, a região enfrenta a maior seca das últimas quatro décadas (LIBONATI, 2020), um fenômeno que reflete os impactos da emergência climática global combinados ao desmatamento nas áreas de nascente dos rios que alimentam o bioma.

Embora historicamente o fogo tenha desempenhado um papel natural no ecossistema pantaneiro, contribuindo, por exemplo, para a renovação de pastagens durante os períodos secos (OLIVEIRA *et al.*, 2014), os incêndios que têm devastado a

região nos últimos anos ultrapassam o limite de suporte do bioma. A ocorrência de focos de maneira descontrolada e em épocas inadequadas, impulsionados por condições climáticas extremas e pressões antrópicas, passa a ameaçar sua estabilidade ecológica, provocando a degradação de habitats, a mortalidade de espécies, prejuízos à saúde humana e à segurança alimentar das populações que dependem do bioma.

1.1 Apresentação do problema

A intensificação dos incêndios no Pantanal tem atingido, de forma alarmante, regiões legalmente protegidas, como as Unidades de Conservação (UCs), comprometendo os objetivos fundamentais de preservação da biodiversidade e manutenção dos processos ecológicos. Criadas com o objetivo de resguardar os ecossistemas naturais e promover o uso sustentável dos recursos, as UCs desempenham um papel estratégico na proteção do patrimônio ambiental e cultural do país. Nessas áreas, busca-se conservar não apenas as espécies da fauna e da flora, mas também os ciclos naturais que regem os ecossistemas, além de garantir os direitos de populações nativas que vivem em equilíbrio com o ambiente (ARRUDA, 1999).

A ocorrência recorrente de incêndios em áreas protegidas representa uma ameaça direta à sua integridade ecológica, gerando impactos duradouros que podem se tornar irreversíveis sobre os sistemas naturais para os quais essas unidades foram originalmente criadas. Esse cenário é particularmente preocupante no Pantanal Mato-Grossense, que abriga importantes UCs federais e estaduais, essenciais para a proteção da biodiversidade e dos processos ecológicos do bioma, como o Parque Estadual Encontro das Águas (PEEA), o Parque Nacional do Pantanal Mato-Grossense e o Parque Estadual do Guirá.

Diante disso, torna-se indispensável o monitoramento contínuo das transformações na paisagem, especialmente no que se refere à manutenção e regeneração das diferentes formações vegetais. Compreender os efeitos do fogo sobre essa diversidade é fundamental para subsidiar ações de prevenção, controle e recuperação ambiental eficazes.

A disponibilidade de dados frequentes sobre a ocorrência, a distribuição espacial e o local de origem das queimadas em uma determinada área é essencial para avaliar com precisão os impactos dos incêndios na paisagem. Essas informações são fundamentais para subsidiar a seleção e priorização de intervenções no território afetado, orientar o

planejamento e o acompanhamento de ações de restauração e recuperação ambiental, além de fornecer uma base sólida para o monitoramento de longo prazo.

Diante dessa necessidade por informações contínuas e confiáveis, o sensoriamento remoto orbital tem se consolidado como uma abordagem eficiente para a aquisição de dados sobre a dinâmica dos recursos naturais. Sua capacidade de fornecer dados atualizados de forma sistemática tem viabilizado o mapeamento recorrente da superfície terrestre em diferentes escalas espaciais, de acordo com a natureza e a complexidade dos elementos analisados. A coleta contínua de imagens por sensores embarcados em plataformas orbitais tem permitido o desenvolvimento de programas robustos de monitoramento ambiental, que contribuem significativamente para diagnósticos precisos em níveis global, regional e local.

Segundo Gómez *et al.* (2016), a análise combinada dos atributos espectrais, espaciais e temporais das imagens de sensoriamento remoto amplia a compreensão sobre os processos naturais e antrópicos que afetam uma determinada região. Essa abordagem tem se mostrado particularmente útil para o monitoramento de áreas sensíveis e para a identificação de eventos singulares, como desmatamentos, queimadas e mudanças abruptas no uso e cobertura da terra, fornecendo subsídios importantes para a gestão ambiental e a tomada de decisões estratégicas.

A aquisição de imagens ópticas em diferentes épocas do ano permite analisar o comportamento espaço-temporal de diversos fenômenos que ocorrem na superfície terrestre, com base nas propriedades espectrais dos seus elementos constituintes. No entanto, fatores ambientais externos ao alvo de interesse, como a presença de nuvens, fumaça e outros componentes atmosféricos, podem comprometer a disponibilidade e a qualidade das imagens, limitando a capacidade de monitorar adequadamente os fenômenos desejados.

A crescente disponibilidade de sensores que operam no espectro de micro-ondas tem ampliado o uso de sistemas orbitais de Radar de Abertura Sintética (*Synthetic Aperture Radar* – SAR) no monitoramento dos recursos terrestres. O SAR é um sensor ativo, o que lhe confere uma vantagem significativa em relação aos sensores ópticos, pois são capazes de adquirir dados independentemente da presença de luz solar e das condições atmosféricas, sendo pouco afetado por nuvens ou fumaça. Essa característica torna o SAR uma ferramenta especialmente atrativa para o acompanhamento de áreas frequentemente cobertas por nebulosidade ou afetadas por queimadas.

Diferentes características das feições da superfície terrestre podem ser discriminadas em imagens de Radar quando comparadas aos dados ópticos, em razão da forma como o sinal de micro-ondas interage com os alvos. Os dados de Radar apresentam alta sensibilidade às propriedades estruturais da vegetação, além de responderem às suas características dielétricas, rugosas e geométricas (DUARTE *et al.*, 2008; RAHMAN *et al.*, 2008; JENSEN, 2009).

Nesse contexto, a polarimetria de Radar, também conhecida como polarimetria SAR (PolSAR), tem sido amplamente explorada em estudos recentes. Essa técnica consiste na análise de diferentes combinações de polarizações do sinal de micro-ondas transmitido e recebido pelo sensor, permitindo a derivação de índices polarimétricos que realçam propriedades biofísicas da vegetação e contribuem para uma melhor discriminação dos alvos na paisagem. As respostas polarimétricas demonstram grande potencial para a classificação de diferentes tipos de uso e cobertura da terra (CAMARGO *et al.*, 2019), bem como para a estimativa de variáveis ecológicas importantes, como biomassa e área foliar em ambientes florestais (PEREIRA *et al.*, 2018).

O desenvolvimento de novos sensores embarcados em plataformas orbitais, aliado aos avanços nas ciências da computação, tem ampliado significativamente as possibilidades de monitoramento dos recursos naturais e antrópicos. A Agência Espacial Europeia (*European Space Agency* – ESA) disponibiliza dados de sensoriamento remoto ópticos e de Radar por meio das missões Sentinel-2 e Sentinel-1, respectivamente. As configurações dessas missões, somadas à alta frequência de revisita e à integração de dados com diferentes características espectrais e espaciais, tornam essas imagens especialmente promissoras para aplicações em monitoramento ambiental.

Um exemplo do potencial dessas informações é apresentado por Tsyganskaya *et al.* (2018), que investigaram a detecção de vegetação sazonalmente inundada na Namíbia com base em séries temporais de dados SAR da banda C e polarização dual do Sentinel-1. O estudo demonstrou que a variação temporal do retroespalhamento é sensível à presença e à duração do alagamento, permitindo identificar áreas com inundações temporárias mesmo sob a cobertura vegetal. Além disso, os autores aplicaram modelos baseados no algoritmo *Random Forest* (RF) para classificar padrões de inundação com alta precisão, destacando o potencial do Sentinel-1 para o monitoramento hidrológico sobretudo em regiões de difícil observação óptica, em função da capacidade de aquisição independente das condições meteorológicas.

O grande volume e a diversidade de imagens atualmente disponíveis, somados à necessidade de tratar e integrar dados heterogêneos multifonte, têm impulsionado o uso de algoritmos baseados em aprendizado de máquina (*Machine Learning* – ML) e aprendizado profundo (*Deep Learning* – DL) para a análise e extração de informações. Esses métodos têm se mostrado fundamentais na busca por soluções sustentáveis voltadas à conservação da biodiversidade. A combinação entre imagens de sensoriamento remoto e algoritmos apropriados para tratar grande volume de dados, tem viabilizado a implementação de diversos programas de monitoramento ambiental, como é o caso do mapeamento anual da cobertura e uso do solo do Brasil do Projeto MapBiomas (<https://mapbiomas.org/>), que disponibiliza mapas anuais dos seis biomas brasileiros a partir da classificação automatizada de imagens Landsat, e, mais recentemente, também com o uso de dados ópticos da missão Sentinel-2.

1.2 Hipótese e objetivos

A utilização do Sensoriamento Remoto óptico na detecção de áreas impactadas por incêndios florestais constitui uma abordagem usual e consolidada no mapeamento de queimadas. Porém, para que o monitoramento direcionado à análise das alterações no uso e cobertura da terra em áreas de conservação ocorra em escalas espaciais e temporais adequadas, é essencial o uso de dados com alta frequência de aquisição, obtidos por sensores capazes de operar mesmo sob condições ambientais adversas, como presença de nuvens e fumaça, além de sensíveis às características estruturais da vegetação. Nesse contexto, considera-se a hipótese de que imagens adquiridas no espectro de micro-ondas permitem o monitoramento sistemático e frequente das queimadas e de seus efeitos sobre a vegetação de uma UC inserida no Pantanal Mato-Grossense, contribuindo para a implementação de estratégias de gestão ambiental mais precisas, contínuas e sustentáveis.

Diante disso, foi selecionado o PEEA, que possui um histórico recorrente de incêndios florestais, com o objetivo geral de desenvolver uma abordagem metodológica que englobe tanto o mapeamento de áreas queimadas, quanto o monitoramento das alterações induzidas pelo fogo na vegetação natural e nos diferentes tipos de uso e cobertura da terra presentes na UC, por meio de atributos polarimétricos SAR. Os objetivos específicos incluem:

- Analisar o potencial de atributos polarimétricos SAR na detecção de áreas queimadas do PEEA;

- Avaliar o desempenho de diferentes algoritmos baseados em aprendizado de máquina e aprendizado profundo na detecção e mapeamento de áreas queimadas em imagens SAR, em comparação com abordagens consolidadas usando dados ópticos;
- Caracterizar o comportamento temporal dos tipos de vegetação e de uso e cobertura da terra da UC, com base na análise integrada das séries temporais de atributos SAR, ópticos e meteorológicos, identificando os padrões sazonais e mudanças abruptas associadas a queimadas; e
- Indicar os atributos polarimétricos mais adequados para o monitoramento da ocorrência de queimadas no PEEA.

Considerando o exposto, a presente pesquisa tem como principal motivação apresentar uma abordagem baseada na utilização de dados contínuos e regulares que permita disponibilizar informações espaciais sobre as queimadas na vegetação natural do PEEA, considerando a dinâmica local e as variações sazonais do Pantanal Mato-Grossense. Busca-se, ainda, desenvolver um método de monitoramento direcionado à análise das alterações no uso e cobertura da terra que representem ameaças aos ambientes naturais e que contribuam para mudanças ambientais globais negativas. Especificamente, pretende-se investigar o impacto das mudanças no uso e cobertura da terra na UC na disseminação das queimadas e na regeneração da vegetação degradada em áreas protegidas, utilizando dados provenientes de imagens SAR.

2. RELEVÂNCIA DA PESQUISA E ESTADO DA ARTE

A pesquisa proposta está diretamente alinhada com diferentes Objetivos de Desenvolvimento Sustentável (ODS) da Agenda de 2030, estabelecidos pela Organização das Nações Unidas (ONU) (Global Goals, 2025). Contribui para o ODS 2 – Fome Zero e Agricultura Sustentável, ao considerar os impactos indiretos das queimadas sobre a produção de alimentos e os serviços ecossistêmicos que sustentam as atividades agropecuárias. Também se relaciona ao ODS 6 – Água Potável e Saneamento, visto que a degradação ambiental no Pantanal afeta diretamente a dinâmica hidrológica e a qualidade da água.

No âmbito do ODS 9 – Indústria, Inovação e Infraestrutura, a pesquisa aplica metodologias inovadoras de sensoriamento remoto e aprendizado de máquina voltadas à gestão ambiental. O estudo ainda se alinha ao ODS 11 – Cidades e Comunidades Sustentáveis, por subsidiar políticas públicas de ordenamento territorial e fortalecimento da resiliência socioambiental, e ao ODS 13 – Ação contra a Mudança Global do Clima, ao abordar estratégias de monitoramento que apoiam medidas de mitigação e adaptação.

Entretanto, a maior contribuição está no ODS 15 – Vida Terrestre. Esse objetivo visa à proteção, recuperação e uso sustentável dos ecossistemas terrestres, incluindo florestas, zonas úmidas, áreas montanhosas e solos, reconhecendo seu papel fundamental na manutenção da biodiversidade e na regulação dos ciclos naturais que sustentam a vida no planeta, aspectos centrais para a conservação do Pantanal e de suas Unidades de Conservação.

A relevância da pesquisa também se conecta diretamente ao cenário global de mudanças climáticas, amplamente documentado por organismos científicos internacionais. O IPCC, criado pela ONU para reunir e avaliar o conhecimento científico sobre o tema, destaca em seu Relatório do Grupo de Trabalho I do Sexto Ciclo de Avaliação (AR6 WGI), publicado em 2021, que a ação humana é a principal responsável pelas alterações climáticas, sobretudo por meio da queima de combustíveis fósseis e do desmatamento (IPCC, 2021). O documento aponta ainda que eventos extremos, como ondas de calor, chuvas intensas, secas e incêndios florestais, estão se tornando mais frequentes e intensos, o que acentua a vulnerabilidade de ecossistemas como o Pantanal.

As contribuições dos Grupos de Trabalho II e III do IPCC, publicadas em 2023 como parte do Relatório de Síntese do Sexto Ciclo de Avaliação (AR6 *Synthesis Report*), reforçam e aprofundam as conclusões anteriores. Esse relatório demonstra que os efeitos

das mudanças climáticas já estão sendo observados em todas as regiões do planeta, com perdas e danos crescentes para as populações humanas e os ecossistemas naturais (IPCC, 2023). Além disso, o relatório evidencia que as metas estabelecidas no Acordo de Paris, adotado em 2015 durante a Conferência do Clima da ONU (COP21), especialmente a limitação do aquecimento global a 1,5°C, estão cada vez mais distantes de serem alcançadas. Nesse cenário, o relatório enfatiza a urgência de reduzir as emissões de gases de efeito estufa de forma imediata, rápida e em larga escala, abrangendo todos os setores da economia.

Esse panorama global de intensificação dos eventos extremos, como o aumento da frequência e severidade de incêndios florestais, tem repercussões diretas no contexto brasileiro, que já enfrenta um cenário crítico relacionado às queimadas em áreas de vegetação nativa. O avanço das mudanças climáticas potencializa os efeitos de fenômenos como secas prolongadas, que contribuem para a propagação do fogo e a devastação de biomas.

Um levantamento realizado pelo Projeto MapBiomas (MapBiomas Fogo – Col. 3, 2025), com base em imagens de satélite de 1985 a 2023, revela que o Brasil teve aproximadamente 200 milhões de hectares queimados ao longo desse período, o que corresponde a cerca de 23% de todo o território nacional. Desse total, 68,4% da área queimada era composta por vegetação nativa, como formações savânicas, campestres e florestais, o que evidencia o impacto direto sobre ecossistemas naturais e a biodiversidade.

O estudo também identificou que os maiores picos de queimadas ocorreram durante a estação seca, principalmente entre os meses de julho e outubro, período que concentra cerca de 79% dos focos de incêndio, com o mês de setembro se destacando como o de maior incidência (34%). Entre os cinco biomas brasileiros, o Pantanal foi o mais afetado proporcionalmente, com 59,2% de sua área total queimada entre 1985 e 2023, o que equivale a aproximadamente 8,9 milhões de hectares atingidos pelo fogo. A média anual de área queimada no bioma, conforme a Coleção 3 do MapBiomas Fogo, foi de 824.567 hectares, o que representa 5,46% da extensão do Pantanal queimada a cada ano. Além disso, do total de área queimada no Pantanal, o levantamento aponta que 91,9% das áreas estavam cobertas por vegetação nativa, reforçando a gravidade dos impactos ambientais nesse bioma frágil e de importância ecológica única.

Esse cenário preocupante evidencia a urgência de avanços tanto no enfrentamento das causas estruturais das mudanças climáticas, quanto no

desenvolvimento de ferramentas que auxiliem no monitoramento de incêndios e na recuperação ambiental em áreas prioritárias. Considerando o papel fundamental que os ecossistemas naturais desempenham na regulação climática global, a presente pesquisa contribui para o avanço do conhecimento científico voltado à conservação ambiental, ao propor abordagens de detecção e monitoramento de queimadas e regeneração de vegetação nativa em áreas protegidas do Pantanal, bioma de extrema importância ecológica, marcado por forte sazonalidade e histórico de incêndios recorrentes e de grande escala. Ao buscar aprimorar as ferramentas de vigilância ambiental e ampliar a capacidade de resposta a eventos críticos, a pesquisa contribui com o fortalecimento de estratégias de conservação, fornecendo subsídios técnicos para a atuação de órgãos gestores e políticas públicas voltadas à proteção de áreas naturais ameaçadas.

Nesse contexto, diversas são as possibilidades de aplicação de técnicas de sensoriamento remoto óptico no estudo da vegetação. O avanço tecnológico, aliado ao desenvolvimento de novos sensores, plataformas de aquisição de dados e ferramentas computacionais capazes de processar grandes volumes de dados, tem impulsionado significativamente as pesquisas voltadas à análise da vegetação natural, bem como ao uso e cobertura da terra (AVETISYAN *et al.*, 2021; GONZALO-MARTÍN *et al.*, 2017; NAGAI *et al.*, 2019; ZHANG *et al.*, 2019). Entre essas aplicações, os estudos voltados ao mapeamento e monitoramento de queimadas em áreas naturais têm ganhado destaque, dada sua importância para a gestão ambiental e a mitigação dos impactos das mudanças climáticas.

Szpakowski *et al.* (2019) destacam que o fogo desempenha um papel significativo na dinâmica dos ecossistemas, na gestão do uso da terra e nos processos ambientais globais. Compreender essa dinâmica, incluindo riscos, padrões de distribuição espacial e efeitos ecológicos, é essencial para avaliar suas influências sobre os sistemas naturais. Segundo os autores, as tecnologias de sensoriamento remoto oferecem uma abordagem eficiente e quantitativa para o estudo da ecologia do fogo em múltiplas escalas. Por meio de uma ampla revisão das aplicações dessas técnicas, os autores enfatizam que o sensoriamento remoto óptico, em particular, representa uma alternativa de baixo custo e com potencial multitemporal para investigações em escalas local, regional e global. Além disso, observam que a pesquisa na área tem evoluído rapidamente com o advento de novas tecnologias e métodos analíticos, o que vem ampliando a precisão e a eficiência dos estudos voltados à dinâmica do fogo.

Elhag *et al.* (2020) realizaram uma avaliação do uso de dados de sensoriamento remoto óptico para o mapeamento de áreas queimadas na Ilha de Tasos, Grécia. O estudo aplicou uma Análise de Componentes Principais (*Principal Components Analysis* – PCA) multitemporal a um par de imagens do satélite Landsat-8, obtidas antes e depois do evento de fogo, com o objetivo de estimar a extensão espacial das áreas queimadas. Além disso, o Índice de Vegetação por Diferença Normalizada (*Normalized Difference Vegetation Index* – NDVI) foi incorporado para aprimorar a acurácia dos resultados. As estimativas geradas foram comparadas com dados de referência fornecidos pelo serviço florestal local, a fim de validar sua precisão. Os autores concluíram que a combinação multitemporal de PCA com o NDVI forneceu os melhores resultados, especialmente devido à capacidade de distinguir áreas queimadas em diferentes anos e à sensibilidade do NDVI às variações de cobertura vegetal.

A severidade do fogo é uma característica chave dos regimes de queima, com grande relevância ecológica e implicações diretas no ciclo global do carbono. Nesse contexto, Delcourt *et al.* (2021) investigaram a gravidade de incêndios em cicatrizes de fogo no nordeste da Sibéria, utilizando imagens Sentinel-2 e dados de campo obtidos em 37 parcelas de florestas de Larício (*Larix cajanderi*). O estudo comparou o desempenho do índice de detecção de queimadas dNBR com o *Geometrically Structured Composite Burn Index* (GeoCBI), uma métrica gerada a partir de observações de campo e medições espectrais com espectrorradiômetro, que reflete a severidade do fogo em múltiplos estratos da vegetação. Os resultados revelaram uma relação linear entre dNBR e GeoCBI, com melhor desempenho em áreas abertas de Larício maduro, confirmando o potencial do índice para estimar a severidade do fogo acima do solo e a profundidade de queima.

Embora amplamente utilizados no monitoramento de áreas queimadas, os sensores ópticos passivos apresentam limitações significativas, como a dependência da luz solar e a forte influência das condições atmosféricas, especialmente a cobertura de nuvens. Em contraste, sensores ativos que operam na faixa de micro-ondas, como o Radar, têm a vantagem de adquirir dados independentemente da luminosidade e do clima. Além disso, esses sensores podem complementar as informações ópticas ao fornecer dados estruturais da vegetação durante o processo de regeneração pós-fogo, devido à alta sensibilidade do sinal retroespalhado às características físicas da vegetação (BAN *et al.*, 2020; ZHOU *et al.*, 2019).

O retroespalhamento do sinal de Radar em áreas vegetadas resulta de interações complexas entre a energia eletromagnética emitida pelo sensor e os elementos de

dispersão presentes na vegetação e no solo dentro de cada célula de resolução. A intensidade desse sinal depende de diversos fatores, incluindo a densidade e a estrutura geométrica da vegetação, propriedades dielétricas, rugosidade da superfície, bem como da frequência e da polarização do sistema de Radar utilizado (DOBSON *et al.*, 1992).

A capacidade dos sensores SAR de adquirirem dados independentemente das condições atmosféricas, aliada à sua alta sensibilidade às propriedades estruturais e dielétricas da vegetação, torna essa tecnologia uma ferramenta promissora para o monitoramento da recuperação da vegetação pós-fogo e para a análise da dinâmica de uso e cobertura da terra. Nesse contexto, diversas pesquisas têm demonstrado o potencial dos dados SAR em múltiplas aplicações.

Vreugdenhil *et al.* (2018), por exemplo, avaliaram o desempenho das polarizações Vertical-Vertical (VV) e Vertical-Horizontal (VH) dos dados do Sentinel-1, bem como a razão entre essas polarizações (*Cross Ratio* – CR), no monitoramento das condições de colheita de culturas agrícolas. O estudo evidenciou, com base em análises quantitativas, o potencial dos índices derivados de micro-ondas no monitoramento da vegetação, particularmente em relação ao conteúdo de água da vegetação e à fenologia. Utilizando o algoritmo RF, os autores integraram dados de retroespalhamento, índices SAR e umidade do solo como variáveis preditoras, identificando o CR como a variável mais relevante para estimar o conteúdo hídrico da vegetação.

Zhou *et al.* (2019) utilizaram imagens SAR das bandas C (polarizações VV e HV) e L (polarização HH), adquiridas antes e depois de um incêndio ocorrido na região do rio Anaktuvuk, na encosta norte do Alasca, com o objetivo de investigar as mudanças na vegetação afetada pelo fogo. Os resultados indicaram que séries temporais de retroespalhamento SAR são eficazes para monitorar a recuperação da vegetação pós-fogo em ambientes de tundra ártica, complementando as observações obtidas por sensores ópticos.

Ban *et al.* (2020) demonstraram o potencial dos dados do Sentinel-1, organizados em séries temporais e analisados por meio de técnicas de *Deep Learning*, no monitoramento da progressão de incêndios florestais. Os autores concluíram que o retroespalhamento do Sentinel-1 é capaz de detectar a ocorrência dos incêndios e acompanhar sua evolução ao longo do tempo, desempenhando um papel relevante no acompanhamento e gestão desses eventos.

Santos *et al.* (2021) desenvolveram uma abordagem para o monitoramento da vegetação no bioma brasileiro Mata Atlântica, contornando as limitações impostas pela

cobertura de nuvens ao empregar dados SAR da missão Sentinel-1. O estudo avaliou o desempenho do índice *Dual Polarization SAR Vegetation Index* (DPSVI) e propôs uma versão modificada, denominada DPSVIm, com o objetivo de aprimorar sua capacidade de monitoramento. Os resultados indicaram que o DPSVIm apresentou melhor desempenho na quantificação da vegetação na área de estudo, mesmo sob influência de variáveis como a topografia e o regime pluviométrico.

Yang *et al.* (2019) investigaram a variação temporal do dossel da vegetação e a relação solo-vegetação em uma área úmida costeira, utilizando dados SAR do Sentinel-1. Os autores construíram modelos tridimensionais para prever propriedades do solo em diferentes profundidades. Os resultados demonstraram que as séries temporais do Sentinel-1 foram capazes de capturar com eficácia as dinâmicas temporais da vegetação, sendo a razão entre as polarizações VH/VV mais sensível ao crescimento do que as polarizações isoladas. Além disso, os dados SAR permitiram prever propriedades químicas do solo, reforçando que a compreensão prévia da variação temporal desses dados é fundamental para o desenvolvimento de estratégias eficazes de predição das características do solo.

Sivasankar *et al.* (2018) realizaram uma revisão sobre os avanços nas tecnologias emergentes aplicadas à agricultura, com ênfase no sensoriamento remoto por Radar. O estudo abordou diversas metodologias baseadas em sensores SAR, incluindo SAR convencional, interferometria SAR (InSAR), Radar de abertura sintética polarimétrico (PolSAR) e interferometria polarimétrica SAR (PolInSAR). Os autores destacaram que a técnica PolSAR apresenta grande potencial para o mapeamento de culturas e a estimativa de parâmetros biofísicos da vegetação, como o índice de área foliar, o teor de água nas plantas e a biomassa.

Bussinguer *et al.* (2024) avaliaram o comportamento temporal de formações florestal, savânica e campestre no Parque Nacional de Brasília, utilizando dados do sensor Sentinel-1 no período de 2017 a 2021. O estudo analisou cinco índices de vegetação SAR: *Dual-Polarized Radar Vegetation Index* (DpRVI), *Radar Vegetation Index* (RVI), *Polarimetric Radar Vegetation Index* (PRVI), *Dual-Polarized SAR Vegetation Index* (DPSVI) e *Modified Dual-Polarized SAR Vegetation Index* (DPSVIm). Todos os índices apresentaram padrão sazonal relacionado ao regime de chuvas. DpRVI e RVI refletiram variações no sinal de Radar em função da sazonalidade, enquanto PRVI, DPSVI e DPSVIm mostraram maior sensibilidade à biomassa e às suas variações sazonais. Entre os índices, o DPSVIm demonstrou o melhor desempenho na distinção entre as classes de

vegetação, especialmente entre as formações florestal e campestre, durante todo o período analisado. Esses resultados indicam que a dinâmica ambiental local exerce forte influência sobre os padrões de resposta dos índices SAR, sendo que a precipitação e as mudanças sazonais na estrutura da vegetação se destacaram como fatores relevantes na alteração e dispersão das distribuições espaciais dos índices ao longo do tempo.

Utilizando dados dos sensores Sentinel-1 e Sentinel-2, Whyte *et al.* (2018) propuseram uma nova abordagem baseada em objetos para o mapeamento de uso e cobertura do solo, com ênfase em zonas úmidas no leste da África do Sul. Foram testados atributos SAR (σ_{VV}^0 , Entropia e Alfa), bandas espectrais do Sentinel-2 (Azul, Verde, Vermelho e Infravermelho próximo), índices espectrais como NDVI e *Modified Normalized Difference Index* (MNDWI), e o Índice de Umidade do Sistema para Análises Geocientíficas Automatizadas (*System for Automated Geoscientific Analyses – SAGA Wetness Index*, SWI). A imagem VH foi descartada após inspeção visual e constatação do baixo contraste em áreas ao redor de corpos d'água, por exemplo. A combinação dos dados se mostrou eficaz, aumentando a acurácia na distinção entre classes úmidas e não úmidas, com destaque para o desempenho do SWI na identificação de ambientes típicos de áreas úmidas, contribuindo significativamente para a qualidade do mapeamento.

Adicionalmente, diversos são os estudos que abordam o monitoramento de florestas queimadas com bases em dados SAR (TARIQ *et al.*, 2021; LASAPONARA; TUCCI, 2019). O uso de dados SAR polarimétricos se destaca por sua sensibilidade à estrutura da vegetação (como orientação, forma e tamanho) e às propriedades dielétricas (como o teor de água no solo e na vegetação), proporcionando uma discriminação mais precisa entre diferentes tipos de cobertura vegetal (LOPEZ-SANCHEZ, 2012). Apesar desse potencial, o uso do SAR para o monitoramento de áreas queimadas ainda é pouco explorado na literatura, especialmente no contexto de regiões tropicais como o Pantanal.

Diante do exposto, a incorporação de imagens SAR na análise dos impactos das queimadas sobre a vegetação natural e os tipos de uso e cobertura da terra no Pantanal Mato-Grossense pode contribuir para o desenvolvimento de metodologias mais precisas e robustas para o monitoramento do bioma. Além disso, a capacidade do Radar de fornecer dados consistentes em cenários que demandam monitoramento frequente, como regiões com alta recorrência de incêndios, possibilita a construção de séries temporais regulares e detalhadas, capturando com maior precisão as dinâmicas pré e pós-fogo e ampliando a compreensão dos impactos das queimadas sobre o bioma.

3. FUNDAMENTAÇÃO TEÓRICA

3.1 Bioma Pantanal

3.1.1 Caracterização do bioma Pantanal

O Bioma brasileiro Pantanal está localizado na região Centro-Oeste do país, abrangendo, majoritariamente, os estados de Mato Grosso e Mato Grosso do Sul, mas sua extensão avança também sobre territórios da Bolívia e do Paraguai. Com cerca de 150.355 km² na porção brasileira, corresponde ao menor bioma nacional em termos de extensão territorial, ocupando aproximadamente 2% do território do Brasil (IBGE, 2019).

O Pantanal é uma zona de transição ecológica entre diferentes biomas sul-americanos, como a Amazônia, o Cerrado, a Mata Atlântica e o Chaco (que abrange territórios da Argentina, Paraguai e Bolívia). Essa condição favorece a ocorrência de uma rica diversidade de espécies da flora e da fauna, adaptadas às variações de paisagem e à dinâmica hídrica característica da região. De acordo com a WWF-Brasil (2025), organização nacional integrante da Rede *World Wide Fund for Nature* (WWF), uma das maiores instituições de conservação ambiental do planeta, a heterogeneidade ambiental do Pantanal proporciona condições propícias para a manutenção de uma elevada biodiversidade, com registros de, ao menos, 325 espécies de peixes, 159 de mamíferos, 98 de répteis, 656 de aves e 53 de anfíbios. Assim como abriga uma rica fauna, o Pantanal também se destaca por sua expressiva diversidade vegetal, podendo ser encontradas na região pelo menos 3.500 espécies de plantas, incluindo formações vegetais aquáticas e terrestres.

Apesar de ocupar uma pequena parcela do território brasileiro, o Pantanal se destaca por sua relevância ecológica, e é considerado a maior área úmida continental do planeta (WWF-Brasil, 2025). Essa singularidade decorre da influência de uma complexa rede hidrográfica que compõe a Bacia do Alto Paraguai (BAP). A dinâmica hidrológica dessa bacia, marcada por variações sazonais entre cheias e secas, é fundamental para a formação das paisagens e para a manutenção da biodiversidade pantaneira. Essa interdependência entre ecossistema e hidrologia confere ao Pantanal um valor ecológico único, sendo reconhecido como Patrimônio Nacional pela Constituição Federal de 1988, além de ter sido declarado Patrimônio Natural da Humanidade e Reserva da Biosfera pela UNESCO em 2000 (UNESCO, 2025).

As bacias hidrográficas, como a BAP, são áreas delimitadas por divisores naturais de água, normalmente situados em regiões mais elevadas, que funcionam como sistemas de captação natural da água das chuvas. Essas águas são escoadas para um ponto de saída comum, o rio Paraguai e seus afluentes, no caso do Pantanal, sustentando os processos ecológicos e a dinâmica da planície inundável.

A BAP é uma bacia transfronteiriça que abrange uma área de aproximadamente 620.000 km², distribuída entre três países: cerca de 60% de sua extensão está localizada no Brasil, enquanto os demais 40% se dividem em áreas aproximadas entre Bolívia e Paraguai (WWF-Brasil, 2009). No território brasileiro, a BAP está situada nos estados de Mato Grosso e Mato Grosso do Sul e abrange, principalmente, os biomas: Pantanal, Cerrado e Amazônia.

A bacia pode ser dividida em duas grandes regiões: a região alta, ou Planalto, e a região baixa, conhecida como Planície. O Planalto ocupa predominantemente os biomas Cerrado (cerca de 83%) e Amazônia (17%), sendo responsável por abrigar as nascentes e os cursos d'água que alimentam a planície pantaneira. Por sua vez, a Planície, localizada integralmente no bioma Pantanal, constitui uma extensa área inundável com altitudes que variam entre 80 e 150 metros, situada na porção central da bacia. Essa área é circundada pelas terras mais elevadas da bacia, os planaltos, que alcançam até 700 metros de altitude (IBGE, 2019). Essas variações topográficas são essenciais para o regime de inundações sazonais que caracteriza o funcionamento ecológico do Pantanal.

A Figura 1 apresenta a porção brasileira da BAP e sua distribuição nos biomas Pantanal, Cerrado e Amazônia. A planície inundável está associada ao bioma Pantanal, enquanto os planaltos correspondem às áreas dos biomas Cerrado e Amazônia, inseridas dentro do limite da BAP. O mapa também destaca alguns dos principais rios da região, como os rios Paraguai, Cuiabá, Taquari, São Lourenço, Itiquira, Miranda, Aquidauana, Negro, Apa e Jauru. Os dados das regiões (bacias) e bases (rios) hidrográficas foram obtidos da Agência Nacional de Águas (ANA, 2020 e 2012, respectivamente), enquanto os limites político-administrativos (estaduais e nacionais), e limite dos biomas brasileiros, foram extraídos da base de dados do IBGE (2024a, 2024b, respectivamente).

Todos os anos, o Pantanal vivencia um ciclo climático bem definido, com estação chuvosa de outubro a março, em que os meses de dezembro e janeiro, correspondem aos maiores registros das precipitações. A estação seca compreende o período de abril a setembro, com destaque para os meses de agosto e setembro, quando se observa o auge da estiagem e a maior incidência de queimadas no bioma (SANTOS *et al.*, 2020).

Esse ritmo anual das águas é essencial para o equilíbrio ecológico do bioma. Segundo o WWF-Brasil (2025), com o início das chuvas nas áreas elevadas da BAP, o nível dos rios aumenta, provocando o alagamento da planície. A extensão da área inundada varia de acordo com o volume de água proveniente do planalto e com o nível do rio Paraguai, que precisa atingir cotas elevadas para transbordar e represar as águas que descem em direção à planície.

Com o fim do período chuvoso, as precipitações param gradualmente e os rios começam a baixar, permitindo que as águas retornem aos seus cursos naturais. Durante esse processo, são formados diversos corixos e vazantes (característicos da paisagem do Pantanal), onde peixes ficam retidos em lagoas e baías, criando um ambiente que atrai inúmeras aves em busca de alimento e que configura um espetáculo natural emblemático do Pantanal. Esse ciclo das águas garante a manutenção das espécies do bioma.

Mudanças climáticas na BAP podem alterar essa dinâmica, comprometendo a conexão entre rios e planícies de inundação, uma interação essencial para a conservação da biodiversidade aquática. Apesar de sua riqueza de fauna e flora, o bioma é considerado frágil, pois qualquer interferência nesse ciclo hidrológico pode colocar em risco sua integridade ecológica, afetando não apenas a biodiversidade regional, mas também os serviços ecossistêmicos fundamentais desse ambiente em escala local e global.

3.1.2 Caracterização das Unidades de Conservação do Pantanal

Com o avanço acelerado do desenvolvimento econômico e o crescimento contínuo da população, aumentam também as pressões sobre os recursos naturais, resultando em problemas graves como o desmatamento, queimadas recorrentes e a perda de biodiversidade (GOVERNO FEDERAL, 2025; AIDA, 2025). Esse cenário é particularmente preocupante nos biomas brasileiros, cuja riqueza ecológica está entre as maiores do mundo.

Nesse contexto, a criação de UCs é fundamental para garantir a proteção de áreas naturais, assegurando a conservação dos ecossistemas, a preservação da fauna e da flora, e a continuidade dos processos ecológicos essenciais para a vida e os serviços ambientais. As UCs atuam como ferramentas estratégicas de ordenamento territorial e gestão ambiental, especialmente em áreas vulneráveis aos efeitos das mudanças climáticas e à degradação da biodiversidade, promovendo um equilíbrio entre o desenvolvimento humano e a conservação ambiental (Angelsen e Kaimowitz, 2001).

Para garantir a proteção efetiva e eficiente das UCs, o governo brasileiro instituiu o Sistema Nacional de Unidades de Conservação da Natureza (SNUC), por meio da Lei nº 9.985, de 18 de julho de 2000 (BRASIL, 2000). De acordo com essa legislação, as UCs são classificadas em dois grandes grupos: Unidades de Proteção Integral e Unidades de Uso Sustentável, que se distinguem principalmente pelo regime de manejo e grau de interferência permitida nos recursos naturais.

As Unidades de Proteção Integral têm como finalidade principal a preservação da natureza, sendo permitido apenas o uso indireto dos recursos naturais. Nessas áreas, a intervenção humana é restrita, sendo autorizadas apenas ações voltadas ao manejo necessário, realização de pesquisas científicas e iniciativas de recuperação ambiental. Esse grupo compreende as seguintes categorias: Estação Ecológica, Reserva Biológica, Parque Nacional, Monumento Natural e Refúgio de Vida Silvestre.

Por sua vez, as Unidades de Uso Sustentável têm como objetivo promover a preservação ambiental aliada à exploração sustentável dos recursos naturais. Nesses espaços, é permitido o aproveitamento econômico racional e planejado, de modo a garantir a manutenção dos ecossistemas. Esse grupo é constituído pelas categorias: Área de Proteção Ambiental; Área de Relevante Interesse Ecológico; Floresta Nacional; Reserva Extrativista; Reserva de Fauna; Reserva de Desenvolvimento Sustentável; e Reserva Particular do Patrimônio Natural (RPPNs) (BRASIL, 2000).

Segundo o Painel de UCs brasileiras do Cadastro Nacional de Unidades de Conservação (CNUC, 2025), iniciativa coordenada pelo Ministério do Meio Ambiente (MMA) em parceria com os órgãos gestores federais, estaduais e municipais, o bioma Pantanal conta atualmente com 29 UCs ativas. Essas unidades estão distribuídas entre os estados de Mato Grosso do Sul (MS) e Mato Grosso (MT), e contemplam tanto o grupo de Uso Sustentável quanto o de Proteção Integral. Entre as categorias de manejo estão os Parques, as Áreas de Proteção Ambiental, as Estações Ecológicas e as RPPNs. As áreas

das UCs dentro do bioma representam 4,68% da extensão de seu território protegida legalmente, totalizando mais de 700 mil hectares.

Ainda de acordo com o Painel do CNUC (2025), a maioria das UCs inseridas no bioma Pantanal é composta por propriedades particulares. Nesses casos, o proprietário pode optar por criar e implementar uma reserva particular em toda ou em parte de sua propriedade. Essas iniciativas voluntárias de proprietários rurais têm um papel importante na conservação ambiental. A criação de RPPNs se destaca como uma das principais estratégias para a preservação das paisagens naturais do Pantanal, contribuindo para a manutenção da biodiversidade.

3.1.3 Transformação do uso e cobertura da terra no Pantanal

Uma análise temporal da cobertura e uso da terra na BAP, entre os anos de 1985 e 2023, realizada a partir dos dados obtidos pela Coleção 9, coleção mais atual de 30 m do MapBiomas (Projeto MapBiomas, 2024), revela dinâmicas contrastantes de supressão de vegetação nativa entre as regiões da planície e do planalto. Na planície pantaneira, foi observada uma perda de 12% das áreas naturais, o que equivale a aproximadamente 1,8 milhão de hectares (Mha). As principais perdas se deram nas classes de Formação Florestal (437.425 ha), Formação Savânica (600.703 ha) e, especialmente, Formação Campestre e Campo Alagado (858.961 ha). A conversão dessas áreas ocorreu majoritariamente para uso com pastagens exóticas, indicando a intensificação da pecuária nessa região.


Por outro lado, no planalto da BAP, a perda foi proporcionalmente mais intensa, atingindo 41% da vegetação nativa, o equivalente a 5,4 Mha. As classes mais afetadas foram Formação Florestal (2,4 Mha), Formação Savânica (2,6 Mha) e Formação Campestre e Campo Alagado (0,33 Mha). A transformação da cobertura no planalto de Formações Florestais e Savânicas, ocorreu principalmente, para coberturas de pastagem.

Esses dados evidenciam que, embora a planície tenha perdido uma menor proporção de cobertura nativa, ela sofreu uma substituição significativa de áreas ecologicamente sensíveis, como campos alagados. Em contrapartida, o planalto passou por uma transformação mais intensa e ampla, associada à expansão do agronegócio, refletindo padrões distintos de pressão antrópica dentro do bioma Pantanal.

Além disso, a análise dos dados da Coleção 9 evidencia uma clara intensificação dos episódios de seca no Pantanal, refletida pela diminuição progressiva da área alagada

e pelo alongamento dos períodos sem inundação. No período de 2019 a 2023, foi observado o menor volume de áreas inundadas de toda a série histórica, com picos de cheia (fevereiro–abril) cada vez menos volumosos e secas (julho–outubro) mais prolongadas e severas. Consequentemente, a área inundável que permanecia alagada por ao menos um mês caiu de 6,9 milhões de hectares em 1988 para apenas 3,4 Mha em 2023, representando quase 50 % de redução nas zonas úmidas perenes, como pode ser visto na Figura 2.

Figura 2 - Área alagada no Pantanal em três anos da série histórica da Coleção 9 do MapBiomias (1988, 2018 e 2023), representando em azul, regiões que ficaram alagadas ao menos uma vez ao longo do ano.



Fonte: Projeto MapBiomias (2024)

Essa retração das águas vem tornando extensas áreas do Pantanal mais suscetíveis a incêndios. A partir de 2020, as queimadas passaram a atingir áreas que antes permaneciam alagadas com frequência, especialmente nas margens do Rio Paraguai. Os dados mostram que os maiores incêndios ocorreram justamente nos períodos de seca prolongada, sendo 2020 e 2021 anos críticos. Além disso, as áreas queimadas no período de 2018 a 2023, incluem tanto planícies quanto planaltos, afetando especialmente formações naturais como campos alagados e savanas.

As análises sobre as queimadas, baseadas nos dados da Coleção 9, indicam uma crescente pressão antrópica sobre o Pantanal, marcada principalmente pela conversão de vegetação nativa em pastagens. Esse processo tem historicamente contribuído para a propagação do fogo, cenário que se agravou nos últimos anos devido ao prolongamento

das estiagens. O conjunto de dados evidencia uma mudança sistêmica no regime hidrológico e no equilíbrio ecológico do bioma, com implicações graves para sua biodiversidade e capacidade de resiliência.

O WWF-Brasil realizou uma retrospectiva das queimadas que ocorreram no Pantanal no ano de 2020, quando o bioma registrou recordes históricos de incêndios florestais. Segundo a organização, aproximadamente 28% da área total do Pantanal foi consumida pelo fogo nos dez primeiros meses daquele ano, resultando na destruição de mais de 4 milhões de hectares (WWF-Brasil, 2020). Entre janeiro e maio, o bioma enfrentou uma intensa estiagem, com volume de chuvas cerca de 50% inferior à média histórica, o que aumentou significativamente a vulnerabilidade da região à propagação do fogo.

Embora o fogo faça parte da dinâmica natural do Pantanal, sendo historicamente utilizado no manejo da vegetação, principalmente em práticas agrícolas e pecuárias (SANTOS *et al.*, 2020), as alterações no regime hidrológico e o uso inadequado do solo têm contribuído para que sua ocorrência se torne cada vez mais imprevisível e de grande impacto ambiental. Em condições extremas de seca, como as observadas em 2020, o fogo se alastra com rapidez por áreas naturais e protegidas, dificultando seu controle e provocando impactos ambientais severos, além de representar uma ameaça concreta à conservação da maior área úmida tropical do planeta.

As áreas protegidas (UCs federais e estaduais) têm sido particularmente afetadas por esses eventos extremos. As UCs representam a estratégia mais eficaz para a conservação da biodiversidade, uma vez que visam preservar a fauna, a flora e os processos ecológicos essenciais para a manutenção dos ecossistemas. No entanto, a ocorrência de incêndios nessas áreas constitui uma das principais causas de degradação ambiental, comprometendo a integridade dos habitats e colocando em risco espécies ameaçadas.

Nesse contexto, o monitoramento contínuo dos diversos tipos de uso e cobertura da terra presentes no Pantanal, assim como a análise dos efeitos do fogo sobre essa diversidade vegetal, é fundamental para compreender a dinâmica socioambiental regional e orientar políticas públicas de mitigação e adaptação frente ao agravamento do cenário climático e ecológico.

3.2 Sensoriamento Remoto óptico

O sensoriamento remoto óptico é uma técnica de obtenção de informações sobre alvos na superfície terrestre, realizada sem o contato físico direto, e caracterizada pelo uso de sensores capazes de detectar e medir a radiação eletromagnética (REM) refletida ou emitida pelos objetos observados. A forma como essa radiação interage com os diferentes materiais permite ao sensor inferir propriedades físico-químicas e biológicas dos alvos imageados. Quando a energia eletromagnética incide sobre um objeto, ela é parcialmente refletida, absorvida e transmitida, produzindo um comportamento espectral característico de cada tipo de material. Esse padrão espectral possibilita sua identificação e diferenciação em imagens de sensoriamento remoto (MORAES, 2002).

Os sensores ópticos passivos constituem uma classe de sistemas imageadores que não possuem fonte própria de REM, sendo, portanto, dependentes de fontes naturais, como a luz solar. Dessa forma, sua operação é limitada a condições diurnas, quando há iluminação solar disponível. Além disso, esses sistemas são significativamente influenciados pelas condições atmosféricas, as quais podem comprometer a qualidade das imagens adquiridas (MOREIRA, 2012).

3.2.1 Comportamento espectral da vegetação


Segundo Jensen (2009), a maior parte da superfície terrestre é coberta por diferentes tipos de vegetação, o que motivou intensos esforços no desenvolvimento de tecnologias capazes de extrair informações biofísicas da vegetação por meio de dados provenientes do sensoriamento remoto. O mapeamento de classes específicas da cobertura vegetal brasileira utilizando imagens de sensoriamento remoto se encontra em pleno desenvolvimento no estado da arte. Exemplos notáveis incluem a classificação das principais formações vegetais do Cerrado dentro de um Reserva Ecológica (RODRIGUES *et al.*, 2025), o mapeamento de três décadas de mudanças na vegetação nativa da savana brasileira (ALENCAR *et al.*, 2020) e a análise da perda de vegetação natural no Mosaico do Jalapão (SANTOS *et al.*, 2022).

A interação da REM com os alvos da superfície terrestre ocorre de maneira distinta conforme suas propriedades físicas e as condições de aquisição da imagem. Esse processo depende de fatores como o comprimento de onda, o ângulo de incidência da energia e a composição dos materiais presentes na superfície. As variações nesses

parâmetros permitem a distinção entre diferentes feições terrestres observadas nas imagens orbitais (LINDGREN, 1985). No caso da vegetação, a magnitude das porções de REM refletidas, absorvidas e transmitidas pela planta possibilita a diferenciação entre distintas espécies vegetais, bem como a identificação de variações fisiológicas dentro de uma mesma espécie.

O conhecimento sobre o comportamento espectral dos diferentes alvos presentes na superfície terrestre é essencial para a adequada extração de informações a partir de imagens orbitais. Na vegetação, sua resposta espectral é influenciada por diversos fatores, como composição bioquímica, morfologia e estrutura interna (PONZONI, 2002). Além disso, as propriedades de reflectância de alvos adjacentes podem interferir na resposta espectral do objeto de interesse, podendo atenuar ou alterar suas características específicas. A curva de reflectância típica de uma folha verde é mostrada na Figura 3.

Figura 3 - Curva de reflectância típica de uma folha verde.



Fonte: Novo (2010)

A Figura 3 pode ser decomposta em três regiões espectrais principais: região do visível (400 a 700 nm); região do infravermelho próximo (*Near InfraRed* – NIR; 700 a 1300 nm); e região do infravermelho médio (*Short Wave InfraRed* – SWIR; 1300 a 2600 nm) (Novo, 2010). Na região do visível, a maior parte da energia incidente é absorvida pelos pigmentos fotossintetizantes presentes no mesófilo da planta. Nessa região, tanto a reflectância quanto a transmitância das folhas são menores que 20%. No entanto, há um pequeno aumento na reflectância da planta no comprimento de onda em torno de 555 nm,

o qual é responsável pela percepção do olho humano da cor verde na vegetação (Novo, 2010).

Na região do NIR, a vegetação apresenta elevada reflectância, variando entre 30% e 40%, e baixa absorção, geralmente inferior a 15%. Esse comportamento está relacionado à interação da REM com a estrutura celular interna da folha, especialmente com o mesófilo. Quanto maior o espaçamento e a complexidade da estrutura interna da planta, maior será o espalhamento da radiação incidente, resultando em níveis mais altos de reflectância (PONZONI, 2002).

No intervalo correspondente ao SWIR, a reflectância da vegetação apresenta uma redução significativa, principalmente devido ao conteúdo de água presente nos tecidos foliares. Nessa faixa espectral, a REM é fortemente absorvida, especialmente entre 1300 nm e 2000 nm, intervalo em que se localizam dois importantes picos de absorção da água, em torno de 1400 nm e 1950 nm (NOVO, 2010).

Diversos fatores podem influenciar a reflectância das folhas, incluindo o teor de água, a idade da folha, a posição nodal, as condições de iluminação, a pubescência e o grau de senescência. O conteúdo hídrico, em particular, exerce grande influência sobre o comportamento espectral da planta. O déficit hídrico nas folhas desencadeia uma série de reações fisiológicas, sendo a primeira delas o fechamento dos estômatos, mecanismo que visa minimizar a perda de água, mas que também reduz a capacidade fotossintética da planta (MOREIRA, 2012). Como consequência, há um aumento da reflectância ao longo do espectro eletromagnético.

De modo geral, na região do espectro visível, plantas com menor teor de água apresentam menor absorção da REM em comparação àquelas com maior teor hídrico, em razão da redução no conteúdo de clorofila. Essa diminuição da absorção resulta, conseqüentemente, em um aumento da reflectância. Além disso, alterações na estrutura interna da folha também contribuem para o aumento da reflectância na região do NIR.

3.2.2 Sensoriamento Remoto óptico na vegetação submetida ao fogo

O sensoriamento remoto óptico tem se consolidado como uma ferramenta fundamental na detecção, mapeamento e monitoramento de áreas afetadas pelo fogo. A análise de dados provenientes de sensores ópticos é amplamente empregada na identificação de cicatrizes de queimada e na quantificação da extensão das áreas impactadas, especialmente em ecossistemas de grande importância ambiental.

A avaliação precisa dessas áreas é essencial para orientar estratégias de recuperação ambiental e mitigação de impactos, como a perda de cobertura vegetal, processos erosivos e alterações nos ciclos hidrológicos. Além disso, o monitoramento contínuo por meio de imagens ópticas permite acompanhar a dinâmica da regeneração da vegetação ao longo do tempo, contribuindo para a compreensão dos padrões ecológicos de resposta ao fogo em diferentes tipos de cobertura do solo.

Os sistemas de sensoriamento remoto fornecem informações biofísicas valiosas sobre as condições do solo e da vegetação antes e após a ocorrência de incêndios. Esses dados têm sido amplamente utilizados para apoiar uma variedade de aplicações, como o mapeamento de áreas de risco de fogo (YU *et al.*, 2017), a caracterização de combustível vegetal, ou seja, biomassa da vegetação que pode queimar durante um incêndio florestal (WAGTENDONK; ROOT, 2003), a detecção ativa de focos de incêndio (SCHROEDER *et al.*, 2016), a estimativa da extensão das áreas queimadas (RANDERSON *et al.*, 2012), a avaliação da severidade da queima (EPTING *et al.*, 2005; MILLER; THODE, 2007; FERNÁNDEZ-MANSO *et al.*, 2016) e o monitoramento da regeneração da vegetação ao longo do tempo (VERAVERBEKE *et al.*, 2012; BRIGHT *et al.*, 2019; NOLÈ *et al.*, 2022).


O fogo provoca mudanças significativas na estrutura da vegetação, nas propriedades físico-químicas do solo e na refletância espectral dos elementos presentes na paisagem queimada. Essas alterações variam consideravelmente em função da diversidade das comunidades vegetais afetadas, da intensidade e duração do fogo, da época do ano em que ocorre e da frequência com que os incêndios se repetem.

Entre os efeitos mais evidentes estão as transformações na vegetação, devido à sua vulnerabilidade às queimadas. O impacto pode levar à redução da cobertura vegetal, perda de biomassa, alterações permanentes na composição da comunidade vegetal, além de mudanças nos padrões da paisagem (PÉREZ-CABELLO *et al.*, 2009). O solo também sofre impactos substanciais, como modificações em sua composição física, química e biológica, afetando processos ecológicos fundamentais.

As mudanças pós-fogo podem ser detectadas por meio de sensores remotos ópticos, que capturam variações na refletância da vegetação ao longo do espectro eletromagnético. A Figura 4 ilustra as curvas da resposta espectral típica de uma vegetação sadia e de uma vegetação queimada, destacando as diferenças de refletância especialmente nas faixas do NIR e do SWIR, que são fundamentais para a construção de

índices de vegetação e para o monitoramento dos efeitos do fogo sobre a cobertura vegetal.

Figura 4 - Curvas de resposta espectral da vegetação sadia (linha verde) e da vegetação queimada (linha vermelha), ao longo do espectro eletromagnético.



Fonte: Adaptado de Wasser e Cattau (2020)

As curvas espectrais apresentadas na Figura 4 evidenciam como o fogo altera significativamente as propriedades ópticas da vegetação. A vegetação sadia apresenta alta refletância na região do NIR e baixa refletância no vermelho, devido à estrutura celular natural e à alta atividade fotossintética. Após a queima, essa estrutura é degradada, resultando em redução acentuada da refletância no NIR e aumento considerável na região do SWIR. As setas na figura evidenciam essas variações, ressaltando os principais contrastes espectrais entre áreas queimadas e vegetação saudável, especialmente nas regiões do NIR e do SWIR.

Essas diferenças espectrais servem de base para a construção de índices espectrais, como o *Normalized Difference Vegetation Index* (NDVI, ROUSE *et al.*, 1974), desenvolvido para quantificar a densidade e o vigor da vegetação, o *Normalized Burn Ratio* (NBR, KEY; BENSON, 1999), amplamente utilizado para detectar áreas queimadas e avaliar a severidade do fogo, e o *Normalized Difference Water Index* (NDWI, MCFEETERS, 1996), que indica o conteúdo de água na vegetação e é capaz de monitorar variações relacionadas à umidade.

A criação de índices espectrais surgiu como uma ferramenta fundamental para traduzir as variações nas curvas espectrais em informações quantitativas e espacialmente definidas, facilitando a interpretação e o monitoramento de eventos como queimadas.

Eles são obtidos por meio de operações matemáticas entre valores numéricos dos pixels de bandas espectrais específicas, com o objetivo de destacar algum evento de interesse.

O NDVI é calculado a partir da diferença normalizada entre o valor de reflectância (ρ) do NIR e da faixa do vermelho. Os valores de NDVI variam de -1 a 1, onde valores próximos a 1 indicam vegetação densa e saudável, enquanto valores próximos a 0 ou negativos podem indicar áreas de solo exposto, água ou cobertura urbana. O NBR, por sua vez, é a diferença normalizada entre as bandas do NIR e do SWIR, sendo reconhecido por sua eficácia na detecção de áreas impactadas por incêndios. Após um evento de queimada, geralmente há uma diminuição significativa na refletância do NIR e um aumento na refletância do SWIR, resultando em valores negativos ou baixos de NBR. Esse índice também pode ser utilizado para avaliar a regeneração da vegetação, uma vez que áreas em regeneração podem apresentar valores mais altos de NBR em comparação com as áreas queimadas.

O NDWI, por outro lado, é calculado a partir da diferença normalizada entre a reflectância no verde e no NIR, e foi desenvolvido para indicar o conteúdo de água na vegetação. Valores elevados de NDWI estão associados à presença de vegetação com maior teor de umidade, enquanto valores mais baixos podem sinalizar estresse hídrico ou áreas afetadas pela perda de biomassa, como após uma queimada. A formulação dos índices NDVI, NBR e NDWI é apresentada na Tabela 1.

Tabela 1 - Formulação dos índices espectrais NDVI, NBR e NDWI. NIR (*Near Infrared*) se refere ao infravermelho próximo e SWIR (*Shortwave Infrared*) ao infravermelho de ondas curtas.

Índices	Equações	Referência
NDVI	$\frac{\rho_{NIR} - \rho_{Vermelho}}{\rho_{NIR} + \rho_{Vermelho}}$	Rouse <i>et al.</i> (1974)
NBR	$\frac{\rho_{NIR} - \rho_{SWIR}}{\rho_{NIR} + \rho_{SWIR}}$	Key e Benson (1999)
NDWI	$\frac{\rho_{Verde} - \rho_{NIR}}{\rho_{Verde} + \rho_{NIR}}$	McFeeters (1996)

Diante dos impactos provocados pelo fogo sobre a vegetação e o solo, o sensoriamento remoto óptico tem se consolidado como uma ferramenta fundamental para o mapeamento e o monitoramento desses eventos. A capacidade de aquisição sistemática de dados multiespectrais em larga escala permite extrair informações valiosas sobre as

condições da superfície terrestre, mesmo em áreas de difícil acesso. Em especial, índices espectrais derivados dessas imagens, como o NDVI, NBR e NDWI, têm se mostrado ferramentas altamente eficazes para detectar alterações na cobertura vegetal, avaliar a severidade das queimadas, monitorar os processos de regeneração pós-fogo e acompanhar variações no conteúdo hídrico da vegetação.

Tais índices ampliam de forma significativa a capacidade de análise temporal e espacial dos impactos causados pelo fogo, fornecendo subsídios valiosos para o planejamento de ações de manejo e conservação ambiental. No entanto, é importante destacar que o sensor óptico é sensível às condições atmosféricas, podendo ter seu desempenho comprometido pela presença de nuvens, fumaça e aerossóis, que limitam a visibilidade da superfície e dificultam a obtenção de imagens contínuas e de qualidade ao longo do tempo.

3.3 Sensoriamento Remoto por micro-ondas

O acrônimo Radar (*Radio Detection and Ranging*) se refere a um sistema de detecção de alvos por meio da emissão e recepção de ondas de rádio. Pulsos eletromagnéticos são transmitidos em direção ao solo e, ao atingirem o terreno ou objetos, são refletidos de volta como ecos. Ao medir o tempo que esses ecos levam para retornar, é possível determinar a distância e a posição dos alvos. O sistema opera com a transmissão de micro-ondas de comprimentos de onda mais longos, variando de 2,4 a 100 cm, através da atmosfera, podendo ser até 200.000 vezes maiores do que os comprimentos de onda da luz visível (MENESES; ALMEIDA, 2012).

A operação em comprimentos de onda relativamente longos apresenta uma importante vantagem em relação aos sensores ópticos: a baixa interferência dos constituintes atmosféricos no processo de aquisição das imagens. Isso significa que, nas cenas de Radar, especialmente naquelas obtidas com comprimentos de onda superiores a 3 cm, a presença de nuvens é rara, o que garante maior continuidade na observação da superfície terrestre.

Além disso, o Radar é um sensor que utiliza uma fonte artificial para gerar a REM, sendo, por isso, classificado como um sensor ativo. Essa característica permite que o imageamento seja realizado independentemente das condições de iluminação solar, possibilitando a aquisição de imagens a qualquer hora do dia ou da noite.

Os comprimentos de onda nas imagens de Radar são identificados por letras. As principais bandas utilizadas estão apresentadas na Tabela 2, juntamente com seus respectivos intervalos de comprimento de onda (em centímetros) e de frequência (em megahertz – MHz).

Tabela 2 - Principais bandas utilizadas pelos sensores de Radar e seus respectivos intervalos aproximados de comprimentos de onda e de frequência.

Banda	Intervalo de comprimento de onda (cm)	Intervalo de frequência (MHz)
X	2,4 - 3,8	12.500 - 7.900
C	3,8 - 7,5	7.900 - 4.000
S	7,5 – 15	4.000 - 2.000
L	15 – 30	2.000 - 1.000
P	30 – 100	1.000 – 300

Fonte: Jensen (2009)

Os sensores ativos de micro-ondas são geralmente classificados em duas categorias principais: imageadores e não imageadores. Entre os sistemas imageadores, a principal diferença está na antena utilizada, que pode ser de dois tipos: Radar de abertura real (*Real Aperture Radar – RAR*) e Radar de abertura sintética (*Synthetic Aperture Radar – SAR*).

Os sistemas pioneiros RAR, apresentavam limitações consideráveis na resolução ao longo da direção do azimute, pois essa resolução depende diretamente do tamanho físico da antena: quanto maior a antena, melhor a resolução. Contudo, há limitações práticas para o uso de antenas grandes em plataformas aéreas ou orbitais, o que compromete a capacidade do RAR de produzir imagens de alta resolução espacial.

Com o avanço das técnicas de processamento de sinais, surgiu o conceito de abertura sintética, permitindo o desenvolvimento dos sistemas SAR. A principal inovação do SAR é a capacidade de simular uma antena muito maior do que a real, ao registrar múltiplos ecos de Radar da mesma área no solo durante o deslocamento da antena ao longo da trajetória da plataforma. Esses dados são então combinados por algoritmos avançados, formando uma “abertura sintética” que proporciona alta resolução espacial, mesmo com antenas fisicamente pequenas.

Essa abordagem supera a principal limitação dos sistemas RAR, cuja resolução em azimute piora com o aumento da distância entre o Radar e o alvo. No SAR, por outro lado, essa resolução permanece constante independentemente da distância, graças à

simulação de uma antena maior por meio da abertura sintética (TREVETT, 1986). Além disso, segundo Jensen (2009), o SAR utiliza uma antena relativamente pequena que emite um feixe de maior abertura, perpendicular à direção do movimento da plataforma. A diferença está no maior número de pulsos enviados e no aproveitamento do deslocamento da antena, que permite sintetizar uma antena virtualmente maior.


Para aprimorar a resolução espacial, o SAR utiliza o efeito Doppler, um fenômeno que ocorre devido ao movimento relativo entre a antena emissora e os alvos no solo. Quando a antena em movimento se aproxima de um alvo, as frequências dos ecos recebidos aumentam; quando se afasta, essas frequências diminuem. Essa variação na frequência dos ecos é analisada para determinar com maior precisão a posição dos alvos ao longo da trajetória da plataforma, o que contribui para a geração de imagens mais nítidas e detalhadas.

Devido a essa capacidade de alta resolução, aliada à independência em relação às condições climáticas e à iluminação, os sistemas SAR tornaram-se ferramentas essenciais no sensoriamento remoto, permitindo a obtenção de imagens precisas da superfície terrestre em qualquer hora do dia, independentemente das condições atmosféricas.

3.3.1 Princípios de funcionamento do SAR

O funcionamento básico de um Radar envolve essencialmente um transmissor, um receptor, uma antena e um sistema eletrônico responsável pelo processamento e registro dos dados. Conforme ilustrado na Figura 5, o feixe de Radar B ilumina a superfície de forma oblíqua, em direção perpendicular ao movimento da plataforma. Simultaneamente, o transmissor emite pulsos curtos e sucessivos de micro-ondas (A). Uma parte dessa energia transmitida é refletida (ou retroespalhada) de volta para a antena (C). Essa energia retroespalhada contém informações sobre os diferentes alvos presentes na área iluminada.

Figura 5 - Funcionamento básico de um Radar.



Fonte: CCRS/NRS (2025)

A partir desse processo, se torna possível medir o atraso de tempo entre a emissão de um pulso e a recepção do "eco" retroespalhado proveniente de diferentes alvos. Esse atraso é utilizado para calcular a distância (ou alcance) até cada alvo. Além disso, a intensidade do sinal retroespalhado permite distinguir entre diferentes tipos de superfícies e objetos. À medida que a plataforma do sensor se desloca, a gravação contínua e o subsequente processamento dos ecos retroespalhados possibilitam a construção de uma imagem bidimensional da superfície terrestre (CCRS/NRS, 2025). De acordo com Jensen (2009), a relação fundamental que descreve o imageamento por Radar pode ser expressa pela Equação 1:

$$P_R = P_T(\sigma^0 A) \frac{G^2 \lambda^2}{(4\pi)^3 R^4} \quad (1)$$

em que P_R é a potência do sinal recebido, P_T a potência do sinal transmitido para o alvo, σ^0 o coeficiente de retroespalhamento, A a área da antena receptora, G o ganho da antena na direção do alvo, λ o comprimento de onda do Radar e R a distância do transmissor ao alvo.


A Equação do Radar expressa o produto entre os parâmetros do sistema e as características da superfície que resultam no retroespalhamento, representado pela seção transversal σ . No contexto do imageamento por Radar, os aspectos mais relevantes estão associados aos efeitos do terreno, especificamente à quantidade de energia refletida pela seção transversal σ por unidade de área (A) do terreno, definida como retroespalhamento normalizado (σ^0). Esse parâmetro é de particular interesse, pois descreve com maior precisão as propriedades radiométricas da superfície (JENSEN, 2009).

3.3.2 Geometria de aquisição de dados do sistema SAR

A geometria de aquisição de dados nos sistemas de Radar é projetada com visada lateral, a fim de minimizar ambiguidades na direção de alcance (LEE; POTTIER, 2009). Caso os pulsos fossem transmitidos diretamente na direção do nadir, sobre uma superfície plana, o Radar identificaria distâncias quase idênticas para diferentes alvos na cena. Como resultado, os ecos retornariam praticamente ao mesmo tempo, impossibilitando a distinção entre os objetos refletidos.

A geometria típica de visada lateral em sistemas de imageamento por Radar é ilustrada na Figura 6. Nesse contexto, a plataforma se move na direção de voo (A), enquanto a direção do nadir (B) está situada diretamente abaixo da plataforma. O feixe de micro-ondas transmitido ilumina uma faixa do terreno (C), que está deslocada lateralmente em relação ao nadir. A letra D representa o alcance ou distância (*range*), isto é, a dimensão transversal perpendicular à direção do voo, enquanto E indica o azimuth, que corresponde à dimensão paralela à trajetória da plataforma (CCRS/NRS, 2025). A Figura 6 também destaca as porções da faixa de imageamento: a porção mais próxima da linha do nadir da plataforma, denominada *near range* (alcance próximo) e indicada por F, enquanto a porção mais afastada do nadir, representada por G, é chamada de *far range* (alcance distante).

Figura 6 - Geometria de visualização lateral de sistemas de imageamento por Radar.




Fonte: Adaptado de CCRS/NRS (2025)

Outros parâmetros relacionados à emissão dos pulsos de Radar pela antena são fundamentais para a definição das características da imagem. Entre eles, destacam-se: a

direção do azimute, a direção de visada, o ângulo de depressão, o ângulo de visada e os ângulos de incidência local, conforme ilustrado na Figura 7.

Figura 7 - Elementos geométricos da configuração de imageamento por Radar.



Fonte: Meneses e Almeida (2012)

A direção de azimute corresponde à direção de voo da plataforma. O pulso de Radar é emitido perpendicularmente a essa direção, iluminando uma faixa do terreno que se estende do *near range* até o *far range*. A direção de visada (também chamada de direção de alcance ou *range*) é a linha ao longo da qual o pulso de Radar se propaga em direção ao solo. O ângulo de visada (ϕ) é o complemento do ângulo de depressão, e é formado entre a linha do nadir (vertical em relação à antena) e a linha de visada do Radar. O ângulo de incidência local (θ_i) é definido entre a linha de visada do Radar e a linha perpendicular à superfície no ponto onde o pulso atinge o terreno. Esse ângulo varia conforme a declividade local, portanto não possui um valor fixo.


Por fim, o ângulo de depressão (γ_i) é formado entre a direção de visada e a linha de visada do Radar em direção a um ponto específico no terreno. Dentro da faixa iluminada, esse ângulo varia do *near range* ao *far range*. Costuma-se adotar como valor representativo o ângulo de depressão correspondente ao ponto médio da faixa de imageamento (MENESES; ALMEIDA, 2012).

Geometrias *Slant Range* (Alcance Inclinado) e *Ground Range* (Alcance no Terreno) da imagem de Radar

A geometria de aquisição de dados em sistemas de Radar difere significativamente daquela observada em sensores ópticos ou outros sistemas convencionais. Por isso, é essencial compreender as características específicas da geometria de imageamento por Radar para uma utilização adequada desses dados.

Uma imagem que ainda não passou por correção geométrica apresenta a chamada geometria de alcance inclinado (*Slant Range*). Essa geometria é baseada na distância real entre a antena do Radar e cada alvo presente na cena (JENSEN, 2009). Conforme ilustrado na Figura 8, a imagem em *Slant Range* é representada no plano que liga a antena ao ponto mais distante da cena, no *far range*. A Figura 8 também mostra os campos A (em *near range*) e B (em *far range*), ambos de mesma dimensão e sem relevo local.

Figura 8 - Geometria *Slant Range* (alcance inclinado)




Fonte: Jensen, 2009

Quando um pulso de Radar incide sobre o início do campo A (ponto 1), com um ângulo de depressão γ_{A1} , sua projeção é registrada no plano de *Slant Range*. O mesmo ocorre no final do campo A (ponto 2) e nos pontos 1 e 2 do campo B. No entanto, ao observar as projeções dos campos A e B nesse plano, percebe-se que o campo A, localizado em *near range*, sofre uma compressão muito maior do que o campo B, em *far range*.

A distância horizontal real no terreno a qual corresponde à projeção da imagem em *Slant Range* sobre a superfície, é chamada de *Ground Range* (G_{rd}). A conversão de *Slant Range* para *Ground Range* envolve a correção geométrica ponto a ponto, garantindo que os elementos da cena sejam representados com precisão em suas posições planimétricas reais na imagem final. A Figura 9 ilustra dois exemplos de uma imagem em *Slant Range*, resultado direto das medições de alcance do Radar (com maior compressão em *near range*), e a imagem corrigida para *Ground Range*.

Figura 9 - Diferença entre as geometrias de imageamento em *Slant Range* e *Ground Range*.




Fonte: Adaptado de ESA (2022a)

Como ilustrado na Figura 9(a), é observada a compressão das feições no *near range* na geometria inclinada (*Slant Range*), enquanto a projeção em *Ground Range* preserva melhor as proporções espaciais reais. Em (b), a comparação reforça visualmente essa distorção. A correção geométrica dessas deformações permite uma distribuição mais uniforme e proporcional das feições ao longo da superfície, evidenciando a importância desse processo para uma representação mais precisa dos dados de Radar.

Como foi mencionado, a geometria de aquisição de imagens de Radar ocorre lateralmente, em uma visada oblíqua. A imagem é originalmente formada com base nos sinais registrados em *Slant Range* (distância inclinada), em vez da verdadeira distância horizontal ao longo do solo (*Ground Range*). Isso provoca certas distorções geométricas nas imagens geradas, decorrentes do deslocamento causado pelo relevo (MENESES; ALMEIDA, 2012).

Em imagens de Radar, objetos mais altos, como árvores, edifícios ou montanhas, aparecem deslocados horizontalmente em direção à antena, devido à sua maior altura em relação aos demais elementos da cena. *Layover* (inversão de relevo) e *foreshortening* (encurtamento de rampa) são dois efeitos geométricos característicos resultantes desse deslocamento causado pela topografia (JENSEN, 2009). Esses efeitos variam em intensidade conforme a posição do terreno em relação ao sensor, sendo mais pronunciados na região de *near range* e menos severos em *far range*, como ilustrado na Figura 10(a).

Figura 10 - Efeitos causados pelo deslocamento do relevo e pela presença de sombras em imagens de Radar: (a) relação entre o *range* (alcance) do terreno e o ângulo de incidência; (b) interação entre a inclinação do terreno e a frente de onda da radiação incidente, influenciando a ordem dos sinais refletidos; (c) aparência da imagem resultante, com destaque para o efeito mais severo de *layover* em *near range* e *foreshortening* mais suave em *far range*; e (d) aumento do comprimento das sombras conforme cresce o ângulo de incidência, evidenciando sua dependência da topografia e da geometria de aquisição.



Fonte: Adaptado de Lillesand *et al.* (2015)

O efeito de *layover* ocorre quando o declive do terreno é suficientemente íngreme a ponto de o topo da encosta ser visualizado antes da base, ou seja, o pulso de Radar atinge primeiro o topo do relevo (Figura 10(b), primeira imagem à esquerda). Como resultado, o sinal refletido pelo topo retorna ao sensor antes do sinal refletido pela base (Figura 10(c), primeira imagem à esquerda). Esse efeito também pode ocorrer quando o ângulo de incidência (Θ) do feixe de Radar é menor do que o ângulo de inclinação da encosta voltada para o sensor.

As encostas do terreno voltadas para a antena, especialmente na região de *near range* (onde os ângulos de incidência são mais acentuados), geralmente apresentam um efeito mais pronunciado de *layover*. Esse fenômeno faz com que uma feição vertical

"sobreponha" elementos mais próximos, dando a impressão de que ela se inclina em direção ao nadir (LILLESAND *et al.*, 2015).

O efeito de *foreshortening* se refere à compressão aparente das superfícies inclinadas voltadas para a direção do pulso de Radar emitido pela antena. Trata-se de uma distorção geométrica do relevo menos severa que o *layover* (Figura 10(c), à direita), mas também mais evidente na região de *near range*.

Outro efeito visto em imagens de Radar é a sombra (*shadow*) (Figura 10(d)). Esse fenômeno ocorre em áreas onde o sinal não consegue atingir a superfície, geralmente devido à combinação entre o ângulo de visada e a inclinação do terreno. As sombras aparecem na direção perpendicular à trajetória da plataforma do sensor, e sua orientação na imagem revela a direção de visada do Radar. O comprimento da região sombreada aumenta com a distância em *range* no terreno, assim como com a diminuição do ângulo de incidência (LUSCH, 1999).

3.3.3 Fatores que influenciam a resposta do Radar


A natureza da REM impede que as micro-ondas interajam diretamente com materiais em nível de átomos e moléculas, o que limita a obtenção de informações sobre a composição dos objetos imageados. Assim, as informações extraídas de imagens de Radar são determinadas principalmente por parâmetros do sensor e por características físicas dos objetos presentes na cena (MENESES; ALMEIDA, 2012).

Entre os principais fatores relacionados ao sensor que afetam a refletividade do sinal de Radar, destacam-se: o comprimento de onda, a polarização da onda, a resolução espacial e a geometria de imageamento. No que se refere aos alvos no terreno, os fatores influenciadores são: a topografia, a rugosidade da superfície, a geometria e orientação dos objetos, além da constante dielétrica dos materiais.

Comprimento de onda e rugosidade da superfície

A rugosidade da superfície é um fator fundamental na determinação da intensidade do sinal retroespalhado em imagens de Radar, estando diretamente relacionada ao comprimento de onda do sensor. Pequenas variações na rugosidade afetam com maior intensidade sinais de sensores que operam com comprimentos de onda curtos, como a banda X, do que aqueles com ondas mais longas, como a banda L, conforme ilustrado na Figura 11.

Figura 11 - Variação da rugosidade da superfície em função da reflexão de Radar de banda X e banda L.



Fonte: Lillesand *et al.* (2015)


Em uma imagem de Radar, uma mesma superfície pode ser interpretada como lisa ou rugosa, dependendo do comprimento de onda utilizado. Para que uma superfície rugosa se comporte como um refletor difuso, espalhando o sinal em todas as direções, é necessário que as variações de altitude da superfície sejam maiores que o comprimento de onda incidente. Por outro lado, uma superfície é considerada lisa quando o sinal não é retroespalhado em direção à antena, refletindo de forma especular. Nessa condição, o comprimento de onda é significativamente maior que as irregularidades da superfície (LILLESAND *et al.*, 2015).

Polarização da onda

O sensoriamento remoto depende de uma fonte de energia que ilumine o alvo, sendo essa energia transportada sob a forma de REM. A REM consiste em dois campos, um elétrico (E) e um magnético (M), os quais oscilam perpendicularmente entre si, ambos

orientados ortogonalmente em relação a direção de propagação da onda, a qual se desloca à velocidade da luz, como ilustrado na Figura 12.


Figura 12 - Orientação espacial dos vetores campo elétrico e campo magnético.



Fonte: CCRS/NRS (2025)

Três propriedades fundamentais das ondas eletromagnéticas são essenciais para sua compreensão: o comprimento de onda, a frequência e a amplitude (Figura 13). O comprimento de onda (λ) é definido como a distância entre duas cristas consecutivas da onda. A frequência corresponde ao número de ciclos completos por unidade de tempo, sendo inversamente proporcional ao comprimento de onda: quanto maior o comprimento de onda, menor a frequência, e vice-versa. A amplitude é a altura da onda, medida entre a crista e o eixo central, e está diretamente relacionada à intensidade da radiação, ou seja, à quantidade de energia transportada por unidade de área (CCRS/NRS, 2025).

Figura 13 - Comprimento de onda, frequência e amplitude de uma onda eletromagnética.



Fonte: Elaborado pela autora.

A energia proveniente de fontes naturais, como o Sol, é geralmente não polarizada, vibrando em todas as direções perpendiculares à direção de propagação. No entanto, em sistemas de Radar, é possível filtrar o sinal para que as oscilações do campo elétrico ocorram apenas em um único plano, tornando a onda polarizada (JENSEN, 2009).

A antena do Radar pode emitir pulsos de micro-ondas polarizados horizontalmente (H) ou verticalmente (V) e pode ser configurada para receber apenas uma dessas polarizações. Quando o pulso incide sobre a superfície terrestre, a interação com os objetos pode provocar a despolarização do sinal, fazendo com que parte da energia retroespalhada retorne com polarização diferente da emitida. Se a antena estiver configurada para aceitar essa polarização alterada, o sinal será registrado (MENESES; ALMEIDA, 2012).

Sistemas de Radar podem operar nos seguintes modos de polarização:

- Co-polarização (ou polarização paralela): o sistema transmite e recebe com a mesma polarização (HH ou VV);
- Polarização cruzada: o sistema transmite e recebe em polarizações diferentes (HV ou VH).

Independentemente do comprimento de onda, os sinais de Radar podem ser transmitidos e/ou recebidos em diferentes modos de polarização. O uso de dados multipolarizados enriquece a capacidade de identificação e discriminação de alvos na superfície terrestre (JENSEN, 2009).

Resolução espacial

Ao contrário dos sistemas ópticos, a resolução espacial de um Radar é determinada por propriedades específicas da radiação de micro-ondas e por efeitos geométricos. Essa resolução depende do comprimento do pulso, que é definido pela duração do tempo em que a antena emite os pulsos de energia, e da largura angular do feixe transmitido pela antena (MENESES; ALMEIDA, 2012).

Para determinar a resolução espacial em qualquer ponto de uma imagem de Radar, é necessário considerar duas dimensões: a resolução em alcance (*range*) e a resolução em azimute.

Resolução em alcance (*range*):

A resolução em alcance, ou *range*, é medida ao longo da direção de propagação do pulso de micro-ondas (iluminação lateral) e depende do comprimento efetivo do pulso

nessa direção. Quanto menor o comprimento do pulso, maior será o nível de detalhe na resolução em *range*.

Por sua vez, o comprimento do pulso é determinado pela velocidade da luz (c) multiplicada pelo tempo de duração do pulso (τ). Como o pulso percorre o trajeto até o alvo e retorna ao sensor, o cálculo da resolução em *Slant Range* (R_{sr}) considera metade do comprimento do pulso, como mostra a Equação 2:


$$R_{sr} = \frac{c \tau}{2} \quad (2)$$

Para converter a resolução da geometria inclinada (*Slant Range*) para a geometria horizontal no solo (*Ground Range* - R_r), multiplica-se R_{sr} pelo cosseno do ângulo de depressão (γ) (Equação 3):

$$R_r = R_{sr} \cdot \cos(\gamma) \quad (3)$$

Para que dois alvos distintos na superfície sejam discriminados na imagem, é necessário que a distância entre eles em *range* seja de, no mínimo, metade do comprimento do pulso. Um exemplo apresentado por Jensen (2009) mostra dois pares de torres com 30 metros de separação: o primeiro par localizado em *near range* (torres 1 e 2) e o segundo em *far range* (torres 3 e 4) (Figura 14), ilustrando como a separação em *range* pode afetar a capacidade de distinção dos alvos.

Figura 14 - Exemplo do cálculo da resolução em *range*.



Fonte: Jensen, 2009

Considerando ângulos de depressão de 65° para as torres localizadas em *near range* e de 40° para as torres em *far range*, com uma duração de transmissão do pulso de $0,1 \mu\text{s}$, a aplicação da Equação 3 para o cálculo da resolução em *range* resulta em $35,5 \text{ m}$ para a região mais próxima da antena (torres 1 e 2 - *near range*); e $19,58 \text{ m}$ para a região mais distante (torres 3 e 4 - *far range*) (JENSEN, 2009).

Para que duas feições possam ser resolvidas, ou seja, distinguidas individualmente em uma imagem de Radar, é necessário que estejam separadas por uma distância maior do que o valor da resolução em *range*. No exemplo citado, as torres 3 e 4, separadas por 30 m , possuem uma distância superior à resolução calculada ($19,58 \text{ m}$), o que permite sua individualização na imagem. Já as torres 1 e 2, também separadas por 30 m , apresentam uma distância inferior à resolução obtida ($35,5 \text{ m}$), o que indica que, provavelmente, não serão resolvidas separadamente e gerarão um único sinal de retorno.


É importante destacar que a resolução no alcance inclinado (*Slant Range*), medida ao longo da linha de visada do sensor, permanece constante, independentemente da posição da feição em relação ao sensor. No entanto, quando essa resolução é projetada no solo (em coordenadas de *Ground Range*), ela passa a variar com o ângulo de incidência: quanto maior o ângulo, maior será a distorção da resolução em solo (CCRS/NRS, 2025).

Resolução em azimute:

A resolução azimutal (R_a) é medida ao longo da direção do voo da plataforma imageadora (isto é, na direção azimutal) e corresponde à largura da faixa do terreno iluminada pelo pulso de Radar nessa direção. Ela é determinada considerando a distância em *Slant Range* (SR), o comprimento de onda (λ) do sistema e o tamanho físico da antena (L), conforme mostra a Equação 4. A Figura 15 ilustra os elementos envolvidos nesse cálculo (JENSEN, 2009).

$$R_a = \frac{SR \cdot \lambda}{L} \quad (4)$$

Figura 15 - Dependência da resolução azimutal em função das distâncias SR (*near* e *far range*) medidas no plano inclinado.



Fonte: Adaptado de Lillesand *et al.* (2015)

Considerando uma distância em *Slant Range* de 20 km para *near range* (SR_1) e 40 km para *far range* (SR_2), uma separação entre os objetos A e B de 200 m em ambas as regiões, e um Radar de abertura real operando na banda X (comprimento de onda de 3 cm), com uma antena de 500 cm, obtém-se a resolução azimutal de 120 m para os objetos em *near range* e de 240 m para os em *far range*.

Com base nesses valores, os objetos mais próximos da antena (em *near range*) possivelmente seriam individualizados, pois a resolução azimutal ($R_{a1} = 120$ m) é menor que a distância entre eles (200 m). Já os objetos mais distantes (em *far range*), cuja resolução azimutal ($R_{a2} = 240$ m) é maior que a separação entre eles (200 m), provavelmente não seriam distinguidos, resultando em um único sinal de retorno.


Segundo Jensen (2009), para melhorar a resolução azimutal, seria necessário aumentar o comprimento físico da antena. No entanto, isso é limitado pelas dimensões das plataformas transportadoras (aeronaves ou satélites). Para superar essa limitação, foi desenvolvida a tecnologia SAR, capaz de sintetizar virtualmente uma antena de maior comprimento com base no movimento da plataforma e no processamento dos sinais coletados, representando uma revolução na obtenção de imagens de alta resolução por Radar, mesmo com antenas compactas.

Ângulo de Incidência

O ângulo de incidência expressa a relação entre a geometria da superfície e seu efeito na interação entre o sinal de Radar e o alvo, afetando diretamente a aparência e o brilho dos objetos na imagem gerada. Esse ângulo desempenha um papel fundamental na forma como a energia do Radar é refletida ou dispersa pelos diferentes elementos da cena (JENSEN, 2009).

Como mencionado anteriormente, o ângulo de incidência é definido entre o pulso de energia emitido pelo Radar e a linha normal à superfície no ponto onde o sinal atinge o terreno. Ele é determinado tanto pela geometria de imageamento do sistema quanto pela topografia local do terreno. A intensidade do sinal retroespalhado varia conforme o ângulo de incidência (Figura 16): os retornos são geralmente mais fortes em ângulos de incidência menores (θ_2) e diminuem à medida que o ângulo aumenta (θ_1) (CCRS/NRC, 2008).

Figura 16 - Variação do ângulo de incidência em função da topografia da região imageada.



Fonte: Adaptado de CCRS/NRC (2008)

Interação do sinal Radar com o terreno

Ao avaliar os retornos do sinal de Radar, é fundamental considerar a forma e a orientação dos objetos, bem como a rugosidade da superfície. Em uma célula de resolução no terreno, pode haver um número grande de alvos difusores distribuídos de forma aleatória, que contribuem para diferentes tipos de espalhamento: coerente e incoerente. (JENSEN, 2009).


Espalhamento incoerente:

No espalhamento incoerente, a fase do sinal de retorno é resultante da soma das fases aleatórias dos difusores elementares presentes na célula de resolução. Os principais mecanismos associados a esse tipo de espalhamento são o superficial e o volumétrico.

No espalhamento superficial, a interação ocorre na superfície do alvo, com parte da energia sendo retroespalhada em direção ao sensor. A intensidade do retorno depende diretamente da rugosidade da superfície, que, por sua vez, está relacionada ao comprimento de onda do sistema de Radar (Figura 11). Superfícies lisas tendem a produzir reflexão especular, em que o sinal é refletido em uma direção oposta à da antena, resultando em baixo retorno. Superfícies moderadamente rugosas geram reflexão mista (especular e difusa), enquanto superfícies altamente rugosas promovem espalhamento difuso, com maior retorno para o sensor (LILLESAND *et al.*, 2015).

O espalhamento volumétrico ocorre quando o sinal do Radar penetra a superfície do alvo e sofre múltiplas interações dentro de um meio, espalhando-se em várias direções. Em ambientes como florestas, esse tipo de espalhamento acontece ao longo de toda a estrutura da vegetação: folhas, galhos, ramos e troncos. Além disso, dentro desse mesmo cenário, pode ocorrer o espalhamento superficial no topo do dossel, quando a energia incide sobre folhas e galhos, e novamente no solo, caso parte da energia atinja o terreno (Figura 17) (JENSEN, 2009).


Figura 17 - Espalhamentos superficial e volumétrico numa hipotética floresta.



Fonte: Jensen (2009)

A Figura 17 apresenta um exemplo de reflexão superficial (nas copas) e de reflexão volumétrica (interação com componentes internos, como galhos e troncos) que podem ocorrer em uma floresta. No entanto, quanto maior for o comprimento de onda, maior será a capacidade de penetração no dossel da vegetação. A Figura 18 ilustra a comparação da interação do sinal de Radar em uma mesma floresta, considerando três diferentes comprimentos de onda.

Figura 18 - Exemplo de contribuição dos espalhamentos superficial e volumétrico em uma floresta para a energia de micro-ondas nas bandas X, C e L.



Fonte: Jensen (2009)

A energia transmitida pela banda de menor comprimento de onda, como a banda X, é atenuada principalmente pelo espalhamento superficial no topo do dossel, causado por folhas e galhos menores (Figura 18c). No caso da banda C (Figura 18b), parte da energia sofre espalhamento superficial no topo da vegetação, enquanto outra parte penetra no interior das árvores, promovendo também espalhamento volumétrico. Uma menor quantidade de energia ainda pode alcançar a superfície do terreno (JENSEN, 2009).


A banda L (Figura 18a), com comprimento de onda maior, possui maior capacidade de penetração no dossel, permitindo que o sinal interaja com diversos componentes internos da vegetação, como folhas, ramos, galhos e troncos, gerando espalhamento volumétrico e promovendo a despolarização do sinal. Parte dessa energia despolarizada pode atingir a superfície do terreno, provocando também espalhamento superficial no limite entre o solo e a vegetação. Comprimentos de onda ainda maiores, como os da banda P (não ilustrada), possuem uma capacidade de penetração ainda mais significativa em vegetações densas, podendo fornecer informações sobre o solo subjacente (JENSEN, 2009).

Espalhamento coerente:

No espalhamento coerente, a fase relativa de cada difusor elementar está altamente correlacionada, resultando em um retorno de sinal mais intenso e organizado. Esse tipo de espalhamento é característico de alvos com geometria bem definida, como edificações orientadas perpendicularmente à direção da radiação incidente, que refletem grande parte da energia de volta para a antena, gerando uma resposta muito brilhante na imagem de Radar (MOREIRA, 2012).

Esses alvos são conhecidos como refletores de canto (*corner reflectors*) e produzem o fenômeno denominado *double-bounce*. Esse efeito ocorre quando o sinal de Radar é refletido entre duas superfícies lisas e perpendiculares, como por exemplo, entre duas faces metálicas de um refletor de canto artificial, ou entre a parede de um edifício e o solo (Figura 19). O pulso percorre esse caminho, atingindo ambas as superfícies lisas, antes de retornar ao sensor, o que intensifica o sinal retroespalhado (JENSEN, 2009).

Figura 19 - Efeito do *double-bounce* em (a) diedro, (b) triedro e em (c) alvos naturais (árvore) e antrópicos (prédio).



Fonte: Elaborado pela autora.

Constante dielétrica

As propriedades elétricas dos objetos na superfície terrestre desempenham um papel fundamental na determinação da intensidade dos sinais de retorno do Radar. Uma dessas propriedades é a constante dielétrica, que expressa a capacidade de um material, como vegetação, solo, rochas, água ou gelo, de conduzir e armazenar energia elétrica quando submetido a um campo eletromagnético (MOREIRA, 2012).

Também chamada de permissividade relativa, a constante dielétrica é uma medida adimensional definida como a razão entre a permissividade dielétrica do material e a permissividade do vácuo ($\epsilon_0 = 8,85 \times 10^{-12} \text{ F/m}$). Essa propriedade indica a capacidade de um material isolante em armazenar carga elétrica. A maioria dos materiais naturais secos (como rochas e solos) apresenta constantes dielétricas entre 3 e 8 na faixa de micro-ondas. Em contraste, a água tem uma constante dielétrica muito mais elevada, próxima de 80 (JENSEN, 2009).

A umidade do solo é um fator que influencia fortemente esse parâmetro. Existe uma relação direta entre o conteúdo de água em um alvo e sua constante dielétrica: quanto maior o teor de umidade, maior será a constante dielétrica e, conseqüentemente, maior o retorno do sinal de Radar. No entanto, a profundidade de penetração da onda

eletromagnética no material é inversamente proporcional ao conteúdo de água, ou seja, materiais com alta umidade dificultam a penetração da onda.

Assim, materiais com maior constante dielétrica apresentam maior interação com o campo elétrico da onda incidente e refletem mais energia para o sensor, enquanto materiais mais secos (com menor constante dielétrica) refletem menos energia, resultando em retorno mais fraco.


Corpos d'água, embora possuam constante dielétrica elevada, tendem a apresentar baixo retorno de sinal nas imagens de Radar. Isso ocorre devido à predominância da reflexão especular: a superfície lisa da água reflete a maior parte da energia incidente em uma direção oposta à da antena, desviando o sinal e impedindo seu retorno direto ao sensor. Como resultado, esses alvos aparecem como áreas escuras (baixa intensidade de brilho) nas imagens de Radar, característica útil na identificação e mapeamento de massas d'água (JENSEN, 2009).

3.3.4 Ruído *Speckle* na imagem de Radar

O *speckle* é um ruído multiplicativo, proporcional à intensidade do sinal recebido, que confere às imagens de Radar uma aparência granulada, semelhante a um padrão de “sal e pimenta”. Esse ruído compromete a qualidade radiométrica da imagem e é resultado da natureza coerente do sinal emitido pelos sistemas SAR (LILLESAND *et al.*, 2015).

A origem do ruído *speckle* está nas interferências construtivas e destrutivas geradas a partir do espalhamento do sinal por múltiplos alvos difusores distribuídos aleatoriamente dentro de uma mesma célula de resolução. Na interferência construtiva, as ondas de retorno chegam em fase uma com a outra, isto é, com seus picos e vales alinhados, somando suas intensidades e resultando em um sinal amplificado (Figura 20(a)). Já na interferência destrutiva, as ondas estão em fases opostas, quando uma atinge o pico, a outra está no vale, o que tende a anular a intensidade do sinal (Figura 20(b)). A Figura 20(c) ilustra o efeito visual resultante dessas interferências dentro de uma célula de resolução, evidenciado pelo padrão granular característico do *speckle* (MENESES; ALMEIDA, 2012).

Figura 20 - Formação do *speckle* em imagem de Radar onde (a) ilustra uma interferência construtiva, (b) interferência negativa e (c) o efeito dessas interferências em uma célula de resolução.



Fonte: Meneses e Almeida (2012)


Além da intensidade (ou amplitude) do sinal retroespalhado em cada polarização, muitos sistemas de Radar, especialmente os polarimétricos, também registram a fase do sinal. A fase corresponde à posição da onda em seu ciclo em um dado instante de tempo e é fundamental para estimar a distância precisa entre o sensor e o alvo. As informações de amplitude e fase são complementares e essenciais para a caracterização e discriminação dos diferentes alvos presentes na superfície terrestre. Enquanto a amplitude reflete a força da resposta do objeto (influenciando diretamente no brilho da imagem), a fase está relacionada à distância relativa do alvo em relação à antena, fundamental em aplicações interferométricas e em medições precisas de distância (MENESES; ALMEIDA, 2012).

Para permitir o acesso a essas informações com precisão, as imagens de Radar são disponibilizadas no formato complexo, conhecidas como *Single Look Complex* (SLC). Nesse formato, cada pixel é representado por um número complexo, cuja parte real corresponde à amplitude e a parte imaginária à fase.

As imagens SLC são geradas por um único “look”, sem a aplicação do procedimento de *multilooking*, e apresentam geometria de alcance inclinado (*Slant Range*), ou seja, não estão projetadas em nenhuma superfície de referência. Como consequência, os produtos SLC mantêm resolução espacial mais elevada no sentido do azimute, mas apresentam o nível máximo de ruído *speckle* (WOODHOUSE, 2006).

A atenuação do *speckle* é comumente aplicada para melhorar a interpretação visual e a análise digital das imagens. Dentre os métodos utilizados para sua redução, destacam-se o processamento *multilooking* e a filtragem espacial (Figura 21). No *multilooking*, o feixe de Radar é subdividido em diversos subfeixes mais estreitos, cada um gerando uma visada (“look”) independente da cena (Figura 21(a)). Todos esses looks sofrem influência do *speckle*, no entanto, a imagem final é produzida com base na média dos retornos dos sinais recebidos, o que reduz a variabilidade do ruído. Esse processo, embora eficaz na redução do ruído *speckle*, implica na perda de resolução espacial (CCRS/NRS, 2025).

Figura 21 - Técnicas utilizadas para redução do *speckle* na imagem de Radar em que (a) se refere ao processamento *multilooking* dividido em 5 looks e (b) filtragem espacial numa janela de tamanho 3x3.



Fonte: CCRS/NRS (2025)

Por sua vez, a filtragem espacial é aplicada diretamente na imagem final, em um ambiente de análise digital. Essa técnica utiliza uma janela móvel (por exemplo, 3x3 ou 5x5 pixels), que percorre toda a imagem nos sentidos das linhas e colunas (Figura 21(b)). Para cada posição da janela, realiza-se um cálculo matemático utilizando os valores de retroespalhamento dos pixels, substituindo o valor do pixel central por um novo valor filtrado. Diversos filtros podem ser utilizados nesse processo, como o filtro da média, da

mediana, *Lee*, *Enhanced Lee*, *Gamma* e *Frost*, sendo a escolha do filtro e do tamanho da janela dependente do tipo de análise a ser realizada e do nível de suavização desejado.

Tanto o processamento de *multilooking* quanto a filtragem espacial promovem a redução do *speckle*, em detrimento da resolução espacial, devido à suavização da imagem. Por essa razão, o nível de atenuação do *speckle* deve ser cuidadosamente ajustado conforme a finalidade da aplicação. Em situações que exigem a preservação de detalhes finos e alta resolução, é recomendável aplicar pouca ou nenhuma filtragem, seja por *multilooking* ou métodos espaciais. Por outro lado, para interpretação visual ou mapeamentos em escalas mais amplas, onde a suavização melhora a legibilidade e reduz o ruído, o uso dessas técnicas de redução de *speckle* se tornam mais adequados e vantajosos (CCRS/NRS, 2025).


3.3.5 Calibração radiométrica

A calibração radiométrica é um processo fundamental para garantir que os valores de pixel em uma imagem de Radar representem de forma precisa as características dos alvos no terreno (ESA(b), 2022). Esse procedimento assegura a confiabilidade na comparação entre as respostas dos alvos, tanto dentro de uma mesma imagem, quanto entre diferentes imagens adquiridas em datas e locais distintos.

Para realizar a calibração radiométrica, é necessário aplicar um fator de correção que possibilite a comparação do retroespalhamento de qualquer objeto presente na cena com o de objetos em outras cenas imageadas. Esse fator ou equação de correção é geralmente fornecido pelo fabricante do sensor. Caso essa informação não esteja disponível, a calibração pode ser realizada com base em alvos de referência conhecidos, como refletores metálicos (*corner reflectors*) e transponders, estrategicamente posicionados na cena (ICEYE, 2025).

A calibração das imagens permite a conversão da refletividade do Radar nas unidades físicas σ^0 , β^0 e γ^0 . Quando expressa em σ^0 , a normalização é feita em relação ao plano de alcance do solo (*Ground Range*); em β^0 , a normalização se refere ao alcance inclinado (*Slant Range*); e em γ^0 , a normalização é feita em um plano perpendicular ao *Slant Range*, ou seja, em direção frontal à onda incidente (ESA(b), 2022). A Figura 22 ilustra a orientação desses diferentes planos de normalização.

Figura 22 - Representação dos planos de normalização utilizados na calibração radiométrica das imagens de Radar: *Ground Range* (σ^0), *Slant Range* (β^0) e plano perpendicular ao *Slant Range* (γ^0).



Fonte: ICEYE (2025)

O processo de calibração radiométrica converte a refletividade do Radar (valores digitais) em coeficientes de retroespalhamento calibrados radiometricamente (σ^0 , β^0 e γ^0). Dessa forma, a amplitude do pixel é extraída diretamente do arquivo de medição (ESA, 2022b).

3.3.6 Atributos Polarimétricos SAR

Os dados polarimétricos provenientes de sistemas de Radar constituem uma fonte essencial de informação na discriminação dos alvos, uma vez que registram informações detalhadas sobre a forma como a energia eletromagnética interage com as características físicas e estruturais das superfícies observadas. No caso das culturas agrícolas, diferentes tipos de cultivo apresentam comportamentos polarimétricos distintos, refletindo variações em parâmetros como densidade, orientação, umidade e estrutura da vegetação. Em contraste, formações vegetais mais densas e heterogêneas, como as copas florestais, tendem a provocar uma forte despolarização do sinal (WOODHOUSE, 2006).

Nesse contexto, a PolSAR tem se consolidado como uma ferramenta poderosa no sensoriamento remoto por Radar. Em comparação com sistemas SAR convencionais de polarização única, os sistemas multipolarimétricos oferecem um volume

significativamente maior de informações, ao registrarem o espalhamento sob diferentes combinações de polarizações: HH, HV, VV e VH. Essas combinações, resultam do uso cruzado das polarizações horizontal e vertical na transmissão e recepção do sinal (CHEN, 2016), permitindo interpretações físicas distintas dos mecanismos de espalhamento presentes na área analisada.

A classificação de imagens multipolarimétricas, no entanto, ainda representa um desafio, pois exige a distinção entre diferentes mecanismos de espalhamento, como o superficial, volumétrico, diédrico ou combinações entre eles. Apesar da complexidade, avanços vêm sendo alcançados na interpretação desses efeitos, visando extrair informações geométricas e radiométricas sobre os alvos.

Nesse sentido, os atributos polarimétricos derivados de imagens SAR desempenham um papel relevante no monitoramento de mudanças na cobertura terrestre, sejam elas provocadas por processos naturais ou por ações antrópicas. Esses atributos resultam da interação da energia emitida pelo Radar com as propriedades dos alvos, como forma, rugosidade e orientação, e refletem os diferentes mecanismos de espalhamento. Por isso, têm sido amplamente empregados em aplicações como a detecção de áreas queimadas (TARIQ *et al.*, 2021; ZHOU *et al.*, 2019; LASAPONARA; TUCCI, 2019), o monitoramento de áreas úmidas (EL HAJJ *et al.*, 2017; WHYTE *et al.*, 2018) e o mapeamento do uso e cobertura da terra (DINIZ *et al.*, 2020).

Esses atributos polarimétricos são obtidos por meio de operações matemáticas entre os coeficientes de retroespalhamento registrados em diferentes polarizações. Diversas métricas foram propostas na literatura ao longo do tempo, algumas das quais estão reunidas na Tabela 3.

Tabela 3 - Formulação de índices polarimétricos em que σ_{VV}^0 e σ_{HH}^0 se referem aos coeficientes de retroespalhamento da energia de Radar nas polarizações paralelas VV e HH, e σ_{VH}^0 e σ_{HV}^0 aos coeficientes de retroespalhamento nas polarizações cruzadas VH e HV, respectivamente.

Nome	Acrônimo	Equação	Referência
<i>Parallel Polarization Ratio</i>	PR	$\frac{\sigma_{VV}^0}{\sigma_{HH}^0}; \frac{\sigma_{HH}^0}{\sigma_{VV}^0}$	Henderson e Lewis (1998)
<i>Cross-Polarization Ratio</i>	CR	$\frac{\sigma_{HV}^0}{\sigma_{HH}^0}; \frac{\sigma_{HV}^0}{\sigma_{VV}^0}$	Henderson e Lewis (1998)
<i>Cross-Polarization Ratio*</i>	CR*	$\frac{\sigma_{VH}^0}{\sigma_{VV}^0}$	-

<i>Biomass Index</i>	BMI	$\frac{\sigma_{HH}^0 + \sigma_{VV}^0}{2}$	Pope <i>et al.</i> (1994)
<i>Canopy Structure Index</i>	CSI	$\frac{\sigma_{VV}^0}{\sigma_{VV}^0 + \sigma_{HH}^0}$	Pope <i>et al.</i> (1994)
<i>Volume Scattering Index</i>	VSI	$\frac{\sigma_{HV}^0}{\sigma_{HV}^0 + BMI}$	Pope <i>et al.</i> (1994)
<i>Radar Forest Degradation Index</i>	RFDI	$\frac{\sigma_{HH}^0 - \sigma_{HV}^0}{\sigma_{HH}^0 + \sigma_{HV}^0}$	Saatchi <i>et al.</i> (2011)
<i>Radar Vegetation Index</i>	RVI	$\frac{\sigma_{HV}^0}{\sigma_{HH}^0 + \sigma_{VV}^0 + \sigma_{HV}^0 + \sigma_{VH}^0}$	Kim e Van Zyl (2009)
<i>Radar Vegetation Index*</i>	RVI*	$\frac{4\sigma_{HV}^0}{\sigma_{HH}^0 + \sigma_{HV}^0}$	Charbonneau <i>et al.</i> (2005)
<i>Radar Vegetation Index**</i>	RVI**	$\frac{4\sigma_{VH}^0}{\sigma_{VV}^0 + \sigma_{VH}^0}$	Nasirzadehdizaji <i>et al.</i> (2019)
<i>Dual Polarization SAR Vegetation Index</i>	DPSVI	$\frac{\sigma_{VV}^0 + \sigma_{VH}^0}{\sigma_{VV}^0}$	Periasamy (2018)
<i>Dual-pol Diagonal Distance</i>	DPDD	$\frac{\sigma_{VH}^0 - \sigma_{VV}^0}{\sqrt{2}}$	Periasamy (2018)
<i>Normalized Ratio Procedure between Bands</i>	NRPB	$\frac{\sigma_{VH}^0 - \sigma_{VV}^0}{\sigma_{VH}^0 + \sigma_{VV}^0}$	Filgueiras <i>et al.</i> (2019)
<i>Polarization Averaging</i>	PA	$\frac{\sigma_{VH}^0 - \sigma_{VV}^0}{2}$	Dos Reis <i>et al.</i> (2019)

As indicações (*) e (**) referem-se a versões sucessivas de um mesmo índice.

O índice PR é utilizado para estimar a rugosidade da superfície, evidenciando diferenças estruturais da vegetação entre as polarizações HH e VV. Por sua vez, o índice CR é sensível ao espalhamento volumétrico típico de formações florestais e, além disso, reduz os efeitos topográficos no sinal de espalhamento. O CR* foi desenvolvido para discriminar entre os mecanismos de espalhamento superficial e volumétrico, sendo particularmente eficaz na identificação de estágios fenológicos iniciais.

O índice BMI é aplicado como indicador da quantidade de biomassa presente, enquanto o CSI mede a relação entre as componentes verticais e horizontais da vegetação. O VSI, por sua vez, é associado à espessura do dossel ou à densidade relativa da vegetação, refletindo predominantemente o espalhamento volumétrico. O índice RFDI contribui para a distinção entre diferentes tipos de vegetação.

O RVI foi originalmente desenvolvido para dados *full polarimetric* com o objetivo de medir a aleatoriedade do espalhamento do sinal de micro-ondas, assumindo valores entre 0 e 1. Valores próximos de zero indicam superfícies lisas, enquanto valores mais altos refletem o crescimento da vegetação. Esse índice é sensível à biomassa e ao teor de água da vegetação. Posteriormente, sua formulação foi adaptada para dados de polarização dual, originando o RVI* e, mais tarde, o RVI**, específico para dados do sensor Sentinel-1.

O DPSVI foi proposto com o objetivo de estimar a biomassa terrestre com base em dados SAR nas polarizações VV e VH. O índice DPDD, foi desenvolvido para analisar dados SAR com polarização dupla, sendo útil na avaliação de características da vegetação. O índice NRPB representa a razão normalizada entre os coeficientes de retroespalhamento obtidos pelo Sentinel-1 e foi criado como variável de entrada em modelos de previsão do NDVI. Por fim, o índice PA foi proposto pelos autores com o intuito de explorar diferentes combinações entre os coeficientes de retroespalhamento dos produtos do Sentinel-1.

3.3.7 Sensoriamento Remoto SAR da vegetação

A interação entre as micro-ondas emitidas pelos sensores SAR e os alvos na superfície terrestre é complexa e influenciada por diversos fatores físicos e operacionais. No caso da vegetação, essa complexidade se intensifica devido à heterogeneidade estrutural dos dosséis. Segundo Carver (1988), qualquer tipo de cobertura vegetal, seja floresta, agricultura ou gramínea, pode ser caracterizado como uma estrutura dinâmica, gerando predominantemente espalhamento volumétrico (ou difuso) do sinal de Radar. Em ambientes florestais, por exemplo, podem coexistir múltiplos mecanismos de espalhamento. A interação repetida da energia com elementos internos do dossel, como folhas, ramos e troncos, pode resultar na despolarização do sinal, característica típica do espalhamento volumétrico.

A resposta de coberturas vegetais ao sinal de Radar é fortemente condicionada por propriedades biofísicas, como o conteúdo de água (relacionado à constante dielétrica), a geometria e a orientação dos elementos do dossel, além da rugosidade da superfície e da topografia do terreno (HARFENMEISTER *et al.*, 2019). A constante dielétrica, em particular, exerce papel fundamental na intensidade do retorno do sinal. Plantas saudáveis, com alto teor de umidade, apresentam uma alta constante dielétrica e,

consequentemente, refletem as micro-ondas de forma mais intensa do que folhas secas ou vegetação em estresse hídrico.

Além disso, parâmetros operacionais do próprio sistema SAR, como o comprimento de onda, a polarização e o ângulo de incidência, também influenciam diretamente a interação da radiação com a vegetação. Comprimentos de onda mais longos, como os das bandas L e P, possuem maior capacidade de penetração, interagindo com as camadas internas do dossel vegetal. Por outro lado, comprimentos de onda mais curtos, como os das bandas C e X, tendem a interagir predominantemente com as camadas superiores da vegetação (JENSEN, 2009).

Quando o comprimento de onda do Radar é semelhante ao tamanho médio dos componentes das plantas, ocorre uma forte combinação de espalhamento superficial e volumétrico. Em dosséis mais densos, esse efeito é ainda mais acentuado, resultando em um forte retroespalhamento do sinal de Radar (LILLESAND, 2015).

De modo geral, comprimentos de onda mais curtos demonstram melhor desempenho na detecção das copas de culturas agrícolas, como soja, trigo e milho, bem como das folhas de árvores, uma vez que o espalhamento volumétrico é predominante e a contribuição do solo subjacente é reduzida. Por outro lado, comprimentos de onda mais longos são mais eficazes na detecção de elementos estruturais mais robustos da vegetação, como troncos e galhos, permitindo uma análise mais aprofundada da estrutura interna do dossel (JENSEN, 2009).


A polarização do sinal também é um elemento determinante na caracterização da vegetação, uma vez que diferentes configurações (HH, HV, VV e VH) produzem respostas distintas dos alvos. Conforme Jensen (2009), a energia polarizada verticalmente é fortemente atenuada por estruturas verticais do dossel, enquanto a energia polarizada horizontalmente sofre menor atenuação. Além disso, o brilho do sinal de retorno tende a aumentar nas imagens com polarização paralela (HH ou VV), devido à maior contribuição do espalhamento superficial. Em contrapartida, nas configurações de polarização cruzada (HV ou VH), o sinal de retorno é intensificado com o aumento da contribuição do espalhamento volumétrico.

Diante da influência direta que características biofísicas da vegetação e parâmetros operacionais do sensor exercem sobre o comportamento do sinal de micro-ondas, é possível compreender como alterações abruptas nesses fatores se refletem nas respostas obtidas por sistemas SAR. Entre essas alterações, destaca-se a ação do fogo, que provoca mudanças significativas na estrutura da vegetação e nas propriedades do

solo, afetando elementos como a rugosidade superficial, a constante dielétrica e a orientação dos componentes do dossel. Essas transformações impactam diretamente o padrão de retroespalhamento, permitindo o monitoramento de eventos de queimada e de seus efeitos sobre a paisagem por meio de séries temporais de dados SAR (ZHOU *et al.*, 2019).

A Figura 23 apresenta um exemplo ilustrativo das características da vegetação antes e depois da ocorrência de fogo, destacando os mecanismos dominantes de espalhamento: o espalhamento volumétrico em condições pré-fogo (Figura 23(a)) e o espalhamento superficial em condições pós-fogo (Figura 23(b)).

Figura 23 - Exemplo de mecanismos dominantes de retroespalhamento de Radar nas bandas C/L, em que (a) se refere ao espalhamento volumétrico antes de um incêndio e (b) ao espalhamento superficial de terreno após um incêndio.



Fonte: Adaptado de Zhou *et al.* (2019)

Como ilustrado na Figura 23, antes da ocorrência do fogo, as ondas de Radar, especialmente nas bandas C e L, interagem majoritariamente com o dossel da vegetação, sendo a maior parte da energia retroespalhada resultante do espalhamento volumétrico. Dessa forma, o sinal SAR se mostra mais sensível às alterações no dossel da vegetação do que às variações na umidade ou na rugosidade do solo.

Após a queimada, a vegetação e/ou parte do solo são consumidos pelo fogo, deixando o solo exposto. Nessa condição, as ondas de Radar interagem principalmente com a superfície do solo, onde o espalhamento superficial passa a ser dominante. O retroespalhamento, nesse estágio, depende fortemente da rugosidade e do teor de umidade do solo. Com o tempo, à medida que a vegetação se regenera, as ondas de Radar passam a interagir cada vez mais com a vegetação em crescimento. Assim, os efeitos da umidade e rugosidade do solo sobre o retroespalhamento diminuem gradualmente devido à atenuação da vegetação em crescimento. Quando a vegetação atinge níveis de densidade

e estrutura semelhantes aos do período pré-fogo, o espalhamento volumétrico volta a ser o mecanismo dominante (ZHOU *et al.*, 2019).

Nesse contexto, a capacidade dos sensores SAR em capturar diferentes aspectos estruturais e biofísicos da vegetação pode tornar o retroespalhamento particularmente sensível a variações na estrutura e condição da vegetação, assim como a possíveis alterações decorrentes de distúrbios como o fogo. Em função dessa sensibilidade, o uso de sensores SAR tem se mostrado promissor em diversas aplicações florestais, como na discriminação de fitofisionomias do Cerrado (SANO *et al.*, 2005), no mapeamento de florestas secas com marcada sazonalidade climática (KOYAMA *et al.*, 2019), na distinção de tipos de cobertura florestal na Amazônia brasileira (CARREIRAS *et al.*, 2017), e na análise dos efeitos da paisagem sobre a recuperação florestal após incêndios (CHRISTOPOULOU *et al.*, 2019).

3.4 Algoritmos de classificação de imagens baseados em aprendizado de máquina

Aprendizado de Máquina (*Machine Learning* - ML) é uma área da inteligência artificial dedicada ao desenvolvimento de algoritmos capazes de identificar padrões em conjuntos de dados e, a partir disso, realizar previsões ou classificações de maneira autônoma. As técnicas de ML têm causado um impacto significativo e abrangente na observação da Terra e no sensoriamento remoto (ZHU *et al.*, 2017 e PERSELLO *et al.*, 2022), uma vez que podem ser aplicadas na integração de grandes quantidades de dados provenientes de diversas fontes para a solução de problemas complexos (LARY *et al.*, 2016).

Além disso, o uso de ML vem se expandindo rapidamente em diferentes áreas das ciências ambientais (CAMPS-VALLS *et al.*, 2021), revolucionando a forma como a informação geoespacial é extraída e interpretada, e se tornando essencial na tomada de decisões em temas críticos, como segurança alimentar, saúde ambiental e gestão de recursos naturais.

Ao contrário dos classificadores supervisionados estatísticos clássicos, esses algoritmos não requerem uma suposição prévia quanto à distribuição estatística das classes e são relativamente tolerantes a ruídos (FILIPPI; JENSEN, 2006). Behmann *et al.* (2015) ressaltam a eficiência de métodos baseados em ML na classificação de dados obtidos por sensores remotos, uma vez que esses métodos utilizam dados de treinamento

representativos das classes de interesse, o que pode compensar a presença de ruídos incluídos no sinal registrado.

Dentre os algoritmos de ML comumente utilizados, estão RF, *Support Vector Machine* (SVM), *Classification And Regression Trees* (CART) e *K-Nearest Neighbors* (KNN). Eles são amplamente encontrados no mapeamento de tipos de uso e cobertura do solo (ZAFAR *et al.*, 2024), estimativa da biomassa florestal (Yan *et al.*, 2023), detecção de mudanças (QU *et al.*, 2019), na agricultura (ASHOURLOO *et al.*, 2022; LI *et al.*, 2025), detecção e análise de áreas alagadas (SHULTS *et al.*, 2025; KURNIAWAN *et al.*, 2025) e mapeamento de carbono orgânico do solo e estoque de carbono em regiões tropicais (BÓCOLI *et al.*, 2025; ARRUDA *et al.*, 2024).

CART, desenvolvido por Breiman *et al.* (1984), é um algoritmo de ML não paramétrico baseado em árvores de decisão, capaz de realizar tarefas de classificação e regressão. Ele divide iterativamente o espaço de dados em regiões homogêneas, utilizando atributos como nós e apresentando as previsões finais nas folhas da árvore.

A construção da árvore começa no nó raiz e prossegue por divisões sucessivas em subnós, guiadas pelo melhor atributo e seu valor de corte, até que sejam formados subconjuntos puros ou atingido o número máximo de folhas. No caso de classificação, CART utiliza a impureza de Gini como critério de divisão. Para evitar *overfitting*, o algoritmo aplica técnicas de poda, removendo nós com baixa relevância, definidos pelo ganho de informação.

O algoritmo RF, desenvolvido por Breiman (2001), é uma técnica de ML baseada no conceito de *ensemble learning*, que combina múltiplas árvores de decisão com o objetivo de aprimorar a acurácia das predições e superar limitações comuns a modelos individuais. Em vez de depender de uma única árvore, o RF constrói diversas árvores de decisão, cada uma treinada com diferentes subconjuntos dos dados originais, gerados por amostragem aleatória com reposição (*bootstrap*).

A predição final é obtida por meio da média dos resultados (regressão) ou do voto majoritário (classificação), o que confere ao modelo maior robustez, estabilidade e capacidade de generalização. Devido a essas características, o RF destaca-se como uma abordagem eficiente e amplamente aplicada em tarefas de classificação e regressão, especialmente em contextos que envolvem grandes volumes de dados complexos, como os provenientes de sensores remotos.

O SVM, proposto por Cortes e Vapnik (1995), é um método de classificação que busca encontrar o hiperplano ótimo que separa as classes de dados em diferentes

categorias, maximizando a distância entre esse hiperplano e os pontos mais próximos de cada classe, conhecidos como vetores de suporte. Quando os dados são linearmente separáveis, o SVM utiliza técnicas de otimização para maximizar a margem de divisão entre as classes.

Sua principal vantagem, no entanto, está na capacidade de lidar com dados mais complexos por meio de funções de *kernel*, como, por exemplo, as funções polinomial, gaussiana ou sigmoide, que transformam os dados para um espaço de maior dimensão, onde a separação linear se torna possível. Essa característica torna o SVM especialmente útil para aplicações em que os padrões são complexos, como na classificação de imagens de satélite.

Por fim, KNN, desenvolvido por Cover e Hart (1967), é um método de aprendizado supervisionado simples e eficaz que classifica dados com base na proximidade entre amostras no espaço de características. Ele parte do princípio de que elementos com características semelhantes tendem a pertencer à mesma classe.

Para realizar a classificação de uma nova amostra, o algoritmo calcula a distância entre a amostra e todas as demais do conjunto de treinamento, utilizando medidas de distância como a distância Euclidiana, Manhattan ou Minkowski. Em seguida, identifica os K vizinhos mais próximos e atribui à amostra a classe mais frequente entre os vizinhos. A escolha do valor de K é um fator determinante, pois valores baixos podem tornar o modelo mais sensível a ruídos (*overfitting*), enquanto valores elevados podem suavizar excessivamente as previsões (*underfitting*).

Dentro do domínio do aprendizado de máquina, o DL representa uma abordagem mais avançada, que emprega redes neurais profundas para processar grandes volumes de dados de forma altamente eficiente e sofisticada. Nesse contexto, destaca-se a rede neural convolucional U-Net, desenvolvida por Ronneberger, Fischer e Brox (2015). A rede U-Net foi projetada originalmente para segmentação de imagens biomédicas, visando identificar estruturas celulares e neurais em imagens de microscopia.

Com o avanço das técnicas de DL e a crescente disponibilidade de dados de sensoriamento remoto, a U-Net expandiu sua aplicação para diversas áreas além da biomedicina. Entre elas, para a detecção de mudanças no uso e cobertura da terra, permitindo a análise da transformação da superfície ao longo do tempo (SEWADA; GOYAL, 2023), na segmentação de áreas agrícolas, auxiliando no monitoramento de culturas, na identificação de padrões de plantio e na gestão de recursos agrícolas (QUOC *et al.*, 2020), além da identificação de áreas afetadas por inundações, em que a rede neural


contribui para a rápida detecção de regiões alagadas, auxiliando na resposta a desastres naturais e no planejamento de medidas preventivas (ROOHI *et al.*, 2025).

A U-Net é uma rede neural convolucional desenvolvida para segmentação de imagens. A segmentação de imagens é realizada pela rede por meio de uma arquitetura que combina redução e aumento de resolução, permitindo capturar tanto o contexto global quanto os detalhes da imagem.

Para compreender de forma mais precisa o funcionamento da arquitetura da rede U-Net, é essencial a definição do conceito de convolução. No contexto da U-Net e das redes neurais convolucionais, a convolução é uma operação matemática usada para extrair padrões e características de uma imagem. Essa operação é essencial para que a rede aprenda a identificar bordas, texturas, formas e outras estruturas dentro da imagem (GOODFELLOW; BENGIO; COURVILLE, 2016).

A convolução funciona aplicando um filtro (ou *kernel*) sobre a imagem de entrada. Esse filtro é uma pequena matriz de números que percorre a imagem realizando operações matemáticas entre seus valores e os dos pixels da imagem. O resultado dessa operação gera um mapa de características que destaca informações relevantes. Na U-Net, diferentes *kernels* são automaticamente aprendidos durante o treinamento, o que permite à rede reconhecer estruturas complexas na imagem e realizar a segmentação com maior precisão. A rede neural U-Net possui estrutura em formato de "U", como pode ser observado na Figura 24, e é composta por duas partes principais: o caminho de contração (*Encoder*), metade esquerda da Figura 24, indicada pelas setas vermelhas que apontam para baixo, e o caminho de expansão (*Decoder*), metade direita da Figura 24, indicada pelas setas verdes que apontam para cima. Ambos os caminhos de contração e expansão passam por múltiplas camadas convolucionais (setas azuis).

Figura 24 - Estrutura da rede neural convolucional U-Net.



Fonte: Ronneberger; Fischer; Brox (2015).

No caminho de *Encoder*, as operações de convolução ajudam a capturar características mais importantes das imagens, seguidas por operações de *max pooling* (setas vermelhas), que reduzem progressivamente a dimensão da imagem, enquanto mantém as informações essenciais. Esse processo ajuda a capturar padrões e características mais abstratas, permitindo que a rede compreenda o contexto geral da imagem. Ao longo dessa fase, o número de mapas de características aumenta, armazenando informações mais ricas sobre os padrões da imagem.

Após atingir a menor dimensão, a rede inicia o processo de reconstrução dos detalhes da imagem segmentada, refinando os limites entre os objetos identificados. Essa etapa envolve operações de *upsampling* (setas verdes), que aumentam progressivamente a dimensão da imagem, recuperando a estrutura espacial original. Durante essa fase, os mapas de características extraídos no *Encoder* são combinados (copiados e concatenados) com o correspondente mapa do *Decoder* por meio de conexões chamadas *skip connections*, ou conexões de atalho (setas cinzas - *copy and crop* - que ligam as camadas de *Encoder* e *Decoder* diretamente). Dessa forma, a rede combina informações de baixo nível (detalhes da imagem) com as de alto nível (padrões aprendidos). Essas conexões são um diferencial importante da U-Net e permitem que ela alcance resultados superiores em tarefas de segmentação (RONNEBERGER; FISCHER; BROX, 2021).

Na arquitetura da rede U-Net apresentada na Figura 24, cada caixa azul representa um mapa de características com múltiplos canais, sendo que a quantidade de

canais está indicada no topo de cada caixa. O tamanho em x e y é especificado no canto inferior esquerdo. Além disso, as caixas brancas correspondem a mapas de características copiados.

Ao final do processamento, a rede transforma os mapas de características processados em um mapa segmentado através da aplicação de uma última camada de convolução 1x1 (seta na cor ciano indicada por conv 1x1 na legenda da Figura 24), em que cada pixel recebe uma classificação correspondente a uma determinada categoria.

A arquitetura da rede U-Net permite ainda, aumentar artificialmente o tamanho do conjunto de dados de treinamento por meio da técnica chamada *Data Augmentation*. A técnica permite produzir imagens a partir de transformações das imagens originais preservando seus rótulos, como translações e reflexões, o que auxilia a reduzir o *overfitting* do modelo (RONNEBERGER; FISCHER; BROX, 2021).

Apesar de suas qualidades promissoras, a arquitetura da U-Net é composta por múltiplas camadas convolucionais e operações que demandam um alto poder computacional para seu treinamento e predição. O processo de aprendizado do modelo envolve a manipulação de grandes volumes de dados, exigindo unidades de processamento gráfico (GPUs) de alto desempenho e memória RAM significativa para acelerar os cálculos matriciais e reduzir o tempo de convergência da rede (GOODFELLOW; BENGIO; COURVILLE, 2016).

Além disso, para que a U-Net segmente as classes desejadas, o treinamento do modelo deve ser feito com dados rotulados (anotação), no qual cada pixel da imagem de entrada está associado a uma classe específica (exemplo: solo, vegetação, água). A rotulagem normalmente é realizada manualmente, e esse pode ser um processo demorado e ineficiente. Porém, existem algumas abordagens que podem ser adotadas para uma rotulação semiautomática. Uma dessas abordagens foi desenvolvida e será apresentada na seção 4.4.3.

3.5 Séries temporais de atributos extraídos de imagens

A análise de séries temporais é uma abordagem estatística e computacional amplamente empregada na investigação de fenômenos que variam ao longo do tempo. No contexto do sensoriamento remoto, essa análise tem ganhado destaque ao possibilitar o monitoramento contínuo de mudanças na superfície terrestre, especialmente por meio de imagens de satélite obtidas de forma sistemática. Essa metodologia permite


acompanhar a evolução de padrões espaciais e processos ambientais, contribuindo para uma compreensão mais profunda das dinâmicas naturais e antrópicas que ocorrem no território.

Ao converter grandes volumes de dados geoespaciais em informações sobre a dinâmica espaço-temporal do uso e cobertura da terra, é possível obter uma perspectiva mais ampla, superando as limitações das análises pontuais, abordagem fundamental para compreender a trajetória e os impactos cumulativos de fenômenos ecológicos e socioambientais (KENNEDY *et al.*, 2010; XI *et al.*, 2021).

Em uma série temporal de atributos extraídos de imagens, os mesmos pixels são registrados em diferentes datas de aquisição, formando uma série temporal individual para cada ponto da superfície. Essa estrutura possibilita a análise da evolução ao longo do tempo das características espectrais de cada pixel, permitindo a identificação de padrões sazonais, mudanças abruptas na cobertura do solo, processos de degradação ambiental, crescimento da vegetação, entre outros fenômenos dinâmicos relevantes (JENSEN, 2009).

A Figura 25 ilustra uma série temporal construída a partir de imagens de satélite adquiridas em diferentes momentos, em que cada pixel mantém sua posição espacial ao longo das diferentes datas de observação. Com essa sequência, é possível extrair a trajetória temporal de um dado pixel, por exemplo, os valores de NDVI entre os anos de 2000 e 2016, permitindo compreender o comportamento de determinados fenômenos, como a dinâmica de queimadas e regeneração da vegetação, naquele ponto específico ao longo do período analisado.

Figura 25 - Sequência de imagens de satélite organizadas ao longo do tempo, formando uma série temporal para um determinado pixel. A linha do tempo representa os valores do índice espectral NDVI, permitindo acompanhar variações na vegetação no intervalo de 2000 a 2016.



Fonte: BRAZIL DATA CUBE (2025)

O uso contínuo de sensores ópticos e de Radar, como os disponíveis nas plataformas Sentinel e Landsat, viabiliza a geração de séries temporais densas e consistentes de indicadores biofísicos (como, por exemplo: os índices espectrais ópticos NDVI, NBR, e os coeficientes de retroespalhamento e índices polarimétricos SAR), os quais podem ser analisados por meio de técnicas de decomposição temporal para extrair padrões relevantes. Dentre essas técnicas, destaca-se o *Breaks For Additive Season and Trend* (BFAST), proposto por Verbesselt *et al.* (2010), que tem como objetivo identificar mudanças estruturais (ou pontos de quebras) em séries temporais, causadas, por eventos como desmatamento, inundações, incêndios etc.

A estrutura geral do modelo BFAST se baseia na decomposição aditiva da série temporal observada, em três componentes principais: tendência (T_t), sazonalidade (S_t), e ruído (e_t), conforme representado pela Equação 5.

$$Y_t = T_t + S_t + e_t, \quad t = 1, \dots, n \quad \text{Equação 5}$$

em que:

- Y_t representa o valor observado da variável de interesse no tempo t ;
- T_t é o componente de tendência, que captura variações estruturais de longo prazo;
- S_t é o componente sazonal, responsável pelas flutuações periódicas; e
- e_t corresponde ao termo de erro ou ruído aleatório (VERBESSELT *et al.*, 2010).

No modelo BFAST, a componente de tendência é representada por uma sequência de segmentos lineares ajustados de forma contínua ao longo da série temporal. Cada segmento é definido por uma equação linear com coeficientes próprios de inclinação (coeficiente angular) e intercepto, permitindo capturar variações graduais no comportamento da variável analisada. A transição entre os segmentos ocorre nos chamados pontos de quebra (*breakpoints*), que correspondem a alterações significativas na trajetória da tendência, como por exemplo, uma queda abrupta devido a súbita redução na vegetação associada a eventos de queimadas. Essa abordagem possibilita uma descrição mais precisa de fenômenos dinâmicos, ao reconhecer e modelar descontinuidades temporais de maneira explícita. A tendência é definida pela Equação 6:

$$T_t = \alpha_j + \beta_j t, \text{ para } t_{j-1}^* < t < t_j^* \quad \text{Equação 6}$$

sendo:

$\alpha_j + \beta_j$ são, respectivamente, o intercepto e o coeficiente angular do segmento j ; e t_j^* indica a posição do ponto de quebra na tendência (VERBESSELT *et al.*, 2010).

Além da tendência, o modelo também pode identificar mudanças na componente sazonal da série temporal. A componente sazonal é modelada de forma adaptativa, ou seja, são utilizados efeitos fixos para representar categorias temporais recorrentes (como meses ou trimestres), e esses efeitos também podem variar entre segmentos temporais distintos, permitindo identificar mudanças na amplitude e na regularidade do padrão sazonal. A representação da sazonalidade é dada pela Equação 7:

$$S_t = \sum_{i=1}^{s-1} \gamma_{i,j} (d_{t,i} - d_{t,0}) \quad \text{Equação 7}$$

sendo:


- Ciclo sazonal é o período completo em que os padrões se repetem (como 1 ano em séries mensais);
- Categoria sazonal é cada subdivisão dentro desse ciclo, como os meses do ano (janeiro, fevereiro etc.) em uma série mensal;
- γ_{ij} representa o efeito da categoria sazonal i no segmento j da série temporal;

- s é o número total de categorias sazonais dentro de um ciclo sazonal completo (por exemplo, se a série for mensal e a sazonalidade for representada por mês, então $s=12$);
- $d_{t,i}$ é uma variável indicadora para a categoria sazonal i , que assume valor 1 quando o tempo t pertence a essa categoria, e 0 caso contrário (VERBESSELT *et al.*, 2010).

Em uma série temporal com resolução mensal, na qual as categorias sazonais correspondem aos meses do ano, temos: $i=1$ para janeiro, $i=2$ para fevereiro, e assim sucessivamente até $i=12$, que representa dezembro. Suponha-se um instante t correspondente a fevereiro de 2021. Nesse caso, a variável indicadora $d_{t,2}$ assume valor 1, pois o tempo t pertence à categoria sazonal $i=2$. Para todas as demais categorias ($i \neq 2$), $d_{t,i} = 0$, uma vez que o tempo t não está associado a essas categorias. Assim, de forma geral, $d_{t,i} = 1$ quando o tempo t pertence à categoria sazonal i , e $d_{t,i} = 0$ caso contrário. Essa estrutura permite ao modelo aplicar os efeitos sazonais de forma pontual, garantindo que cada componente sazonal atue apenas no período correspondente.

A Figura 26 apresenta um exemplo da aplicação do algoritmo BFAST em uma série temporal do índice espectral de vegetação NDVI, derivada de imagens do sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS), com intervalo de 16 dias. O estudo foi conduzido por Verbesselt *et al.*, (2010) em uma área florestal no sudeste da Austrália, com o objetivo de detectar e caracterizar mudanças espaciais e temporais na paisagem florestal.

Figura 26 - Componentes ajustados de sazonalidade e tendência para uma série temporal do índice NDVI a partir de imagens MODIS com intervalo de 16 dias, correspondentes a uma plantação de pinheiros no sudeste da Austrália. A componente de erro foi ocultada e não será analisada neste estudo.



Fonte: Adaptado de Verbesselt *et al.* (2010).


Os resultados da decomposição de uma série temporal NDVI usando o algoritmo BFAST apresentados na Figura 26 destacam os componentes de dados originais (*data* ou Y_t), sazonalidade (*seasonal* ou S_t) e tendência (*trend* ou T_t). O painel superior (*data*) mostra os valores observados ao longo do tempo, enquanto o segundo (*seasonal*) exibe o comportamento sazonal regular da vegetação, refletindo padrões cíclicos associados a variações climáticas ou fenológicas.

No terceiro painel (*trend*), observa-se a tendência com três pontos de ruptura claramente identificados. Cada ponto marca uma mudança significativa na trajetória da tendência, sendo visualmente identificados por linhas verticais tracejadas e intervalos de confiança em vermelho. O componente residual foi omitido por não ser objeto de investigação neste estudo. A Figura 26 reforça a capacidade do BFAST de isolar e identificar alterações estruturais tanto em tendências quanto em padrões sazonais em séries temporais ambientais. O algoritmo BFAST foi desenvolvido e está disponível na linguagem R, por meio do pacote *bfast*.

Como mencionado anteriormente, o método BFAST permite decompor uma série temporal nos componentes de tendência, sazonalidade e ruído, além de detectar pontos de quebra nesses componentes ao longo do tempo. Esses pontos, apresentados no componente de tendência, indicam mudanças estruturais nos dados causadas, por exemplo, por alterações devido a queimadas, desmatamento ou regeneração da vegetação.

Com essa decomposição, o BFAST possibilita uma análise detalhada do comportamento da série temporal em diferentes períodos, delimitados pelos pontos de quebra. Cada segmento entre duas quebras pode ser interpretado individualmente, permitindo compreender a dinâmica dos processos analisados. Entre os principais resultados extraídos pelo BFAST para os segmentos definidos entre os pontos de quebra, destacam-se o coeficiente angular (β) (tendência) e o p-valor (*p-value*). A Figura 27 apresenta um exemplo de resultado obtido nesse estudo do método BFAST, a uma série temporal de um índice polarimétrico (PA) na classe Formação Savânica (FS), ilustrando a identificação de um ponto de quebra, bem como os valores estimados de tendência (β) e o respectivo p-valor. A metodologia aplicada para a geração da figura e análise dos resultados obtidos, serão apresentados nos capítulos de metodologia e resultados, respectivamente.

Figura 27 - Aplicação do BFAST a uma série temporal do atributo PA na classe FS, ilustrando a identificação de um ponto de quebra (linha tracejada vertical em T_t), e os valores de tendência (β) e p-valor estimados para cada segmento.



Fonte: Elaborado pela autora.

Os principais parâmetros extraídos do modelo BFAST, coeficiente angular (β) e p-valor, podem ser definidos e interpretados da seguinte forma:

- **Coeficiente Angular (β) – Tendência**, corresponde aos coeficientes de inclinação das tendências lineares ajustadas em cada segmento, indicando a direção e a intensidade das mudanças graduais ao longo do tempo. Esse coeficiente pode ser interpretado da seguinte forma:
 - $\beta > 0$: tendência de aumento (indicando recuperação ou crescimento);
 - $\beta < 0$: tendência de queda (indicando degradação ou redução);
 - $\beta \approx 0$: tendência estável (sem mudança significativa).

Além do sinal, a magnitude de β reflete a intensidade da mudança: valores elevados em módulo (positivos ou negativos) indicam mudanças rápidas, como fortes declínios ou recuperações bruscas; enquanto valores próximos de zero indicam mudanças graduais ou estabilidade.

- **p-valor (p-value)**: mede a significância estatística da tendência β observada em cada segmento, e pode ser interpretado da seguinte forma:

- $p \leq 0,05$: a tendência é estatisticamente significativa, com alta confiança;
- $0,05 < p \leq 0,1$: a tendência apresenta evidência moderada de significância;
- $p > 0,1$: a tendência não é estatisticamente significativa (não há evidência suficiente para afirmar que a mudança não ocorreu por acaso).

É importante ressaltar que um p-valor elevado não implica necessariamente na ausência de uma tendência real, apenas indica que não há evidência estatística suficiente para confirmar que a mudança é diferente de uma variação aleatória.

A decomposição da série temporal por meio do BFAST, também permite isolar a componente sazonal (S_t), responsável por capturar padrões periódicos que refletem diretamente a resposta das comunidades vegetais às variações sazonais ambientais. De acordo com Gao *et al.* (2021), a amplitude da sazonalidade constitui um indicador sensível do estado da vegetação, uma vez que áreas ecologicamente íntegras tendem a apresentar dinâmicas sazonais mais pronunciadas, marcadas por oscilações claras entre os períodos de maior e menor vigor vegetativo.

Em contrapartida, reduções na amplitude sazonal ao longo do tempo podem indicar processos de degradação, como diminuição da cobertura vegetal, comprometimento da biomassa ou impactos recorrentes de perturbações ambientais. Assim, a estabilidade e a magnitude da componente sazonal são consideradas métricas importantes para avaliar a vitalidade ecológica e a resiliência da vegetação frente a distúrbios naturais e antrópicos.

Outro parâmetro essencial na aplicação do BFAST é o valor de h , que define o tamanho mínimo de um segmento entre dois pontos de quebra (*breakpoints*). Esse parâmetro exerce influência direta na sensibilidade do modelo à detecção de mudanças estruturais, atuando como um fator de controle para evitar a identificação de quebras espúrias causadas por ruídos ou variações de curta duração. Valores menores de h aumentam a sensibilidade do modelo, mas também a suscetibilidade ao ruído (VERBESSELT *et al.*, 2010).

Ainda de acordo com Verbesselt *et al.* (2010), a escolha de h deve considerar a resolução temporal da série e a duração típica das mudanças que se busca identificar ao

longo do tempo. O estudo de Watts e Laffan (2013) avaliou a sensibilidade do algoritmo BFAST ao parâmetro h , em séries temporais de índices de vegetação derivados de dados MODIS. Os autores testaram três valores distintos ($h = 1/3, 1/5$ e $1/7$), definidos como frações do comprimento total da série temporal, ou seja, h/N , em que N representa o número total de observações na série. Por exemplo, em uma série com 72 observações mensais, $h = 1/6$ corresponderia a um segmento mínimo de 12 meses ($h/N = 12/72 = 1/6$).

Os autores observaram que a redução do valor de h resultou em um aumento no número de quebras detectadas e na magnitude das mudanças na tendência. Além disso, a precisão temporal das quebras detectadas também melhorou com a diminuição de h , especialmente para o índice de vegetação óptico *Enhanced Vegetation Index* (EVI). No entanto, os autores destacaram que a escolha do valor de h deve considerar a resolução temporal dos dados e a natureza dos processos que se deseja identificar, indicando que não há um valor universalmente ótimo para todas as situações.

4. MATERIAIS E MÉTODOS

4.1 Especificação da área de estudos

A área de estudo selecionada corresponde ao Parque Estadual Encontro das Águas (PEEA), uma UC de proteção integral situada no bioma Pantanal. A escolha do PEEA como área de estudo, fundamenta-se em sua alta relevância ecológica dentro da dinâmica do bioma Pantanal. Dos mais de 700 mil hectares do bioma protegidos legalmente por meio de UCs, o parque corresponde a uma parte significativa dessa extensão, cerca de 108 mil hectares. Além disso, o seu histórico de incêndios florestais recorrentes insere a unidade em um contexto crítico para a investigação de impactos do fogo em ambientes protegidos.

A delimitação da área de estudo dentro de uma UC também se justifica pelo papel estratégico que essas unidades desempenham na preservação ambiental, especialmente diante dos desafios impostos pelas mudanças climáticas, que tendem a intensificar eventos extremos, como secas prolongadas e incêndios. A esses desafios somam-se as pressões antrópicas, como o desmatamento, o uso inadequado do solo e as queimadas intencionais, que aumentam ainda mais a vulnerabilidade desses ecossistemas.

A seleção de uma área com histórico significativo de incêndios permite a construção de uma base de dados robusta para análises temporais, possibilitando a avaliação tanto dos efeitos imediatos do fogo quanto dos processos de regeneração da vegetação ao longo do tempo. Nesse contexto, busca-se também desenvolver e aprimorar metodologias de mapeamento e monitoramento desses eventos ao longo do tempo, com ênfase no uso de dados oriundos do sensoriamento remoto por Radar (SAR), visando contribuir com estratégias mais eficazes de gestão e conservação voltadas à mitigação dos impactos do fogo em áreas protegidas.

4.2 Área de Estudos: Parque Estadual Encontro das Águas


A área de estudos, o PEEA, está localizada na região sul do estado de Mato Grosso, entre os municípios de Poconé e Barão de Melgaço. Criada em 2005, a unidade possui área total superior a 108 mil hectares e é administrada pela Secretaria de Meio Ambiente do Estado de Mato Grosso (SEMA). A Figura 28 apresenta a localização geográfica e a caracterização topográfica do parque, com base em dados do Modelo

Por estar integralmente inserido no Pantanal, o PEEA reflete as características climáticas, geomorfológicas e hidrológicas típicas do bioma. Dessa forma, o parque apresenta um clima tropical sazonal úmido, com duas estações bem definidas: uma chuvosa, que se estende de outubro a abril, e outra seca, entre maio e setembro. Esse regime pluviométrico acentuadamente sazonal é determinante para a dinâmica ecológica do Pantanal e influencia diretamente a frequência e intensidade dos eventos de fogo, sobretudo em anos marcados por extremos climáticos (SANTOS *et al.*, 2020).

Entretanto, essas mesmas características que sustentam a riqueza ecológica da região, também a tornam especialmente vulnerável a eventos extremos. Em 2020, ano em que o bioma Pantanal enfrentou a mais severa seca das últimas décadas (LIBONATI, 2020), essas condições favoreceram a propagação de incêndios de grande magnitude, resultando em impactos devastadores sobre extensas áreas naturais. Nesse ano, o PEEA foi particularmente afetado, com estimativas indicando que mais de 85% de sua área foi consumida pelo fogo (MENEGASSI, 2025; BARONI, 2025). A gravidade da situação atraiu ampla cobertura da mídia nacional e internacional (NASA EARTH OBSERVATORY, 2025; THE GUARDIAN, 2025), ressaltando a necessidade urgente de se estabelecerem estratégias eficazes de monitoramento, mitigação e prevenção de incêndios em Unidades de Conservação.


A Figura 29 mostra os focos de queimadas registrados pelo Programa Queimadas do INPE (2025b) no PEEA durante o ano de 2020, discriminados por mês. Esse programa realiza o monitoramento e modelagem da ocorrência e propagação e classificação do fogo ativo na vegetação, utilizando técnicas de Sensoriamento Remoto, Geoprocessamento e Modelagem Numérica. Adicionalmente, a Figura 30 apresenta imagens do satélite Sentinel-2 (composição R4G3B2) da área do parque, registradas nos períodos pré-fogo (20/07/2020) e pós-fogo (22/11/2020).

Figura 29 - Distribuição espacial dos focos de queimadas no PEEA ao longo de 2020, discriminados por mês, considerando apenas os meses com registros, conforme dados do Programa Queimadas do INPE.



Fonte: Elaborado pela autora com dados do INPE (2025b).

Figura 30 - Imagens ópticas do PEEA do sensor Sentinel-2, pré e pós-fogo (20 de julho e 22 de novembro de 2020, respectivamente), em composição colorida verdadeira (R4G3B2).




Fonte: Elaborado pela autora.

A comparação das imagens ópticas pré e pós- fogo (20 de julho e 22 de novembro, respectivamente) da Figura 30 ilustra a extensão da área da UC impactada pelas queimadas, com alterações significativas, o que evidencia a degradação da vegetação causada pelo incêndio. Conforme ilustra a Figura 29, quase 500 focos de queimadas foram observados no ano de 2020 no PEEA. A distribuição mensal evidencia

uma concentração expressiva nos meses de setembro (395 focos) e agosto (73 focos), coincidindo com o período de seca mais intensa no bioma Pantanal.

De forma semelhante, nos anos de 2023 e 2024, o PEEA voltou a registrar um número expressivo de focos de queimadas, evidenciando a recorrência do fenômeno na UC. A Figura 31 mostra a distribuição espacial dos focos de queimadas no parque nesses anos, discriminados por mês, também obtidos do Programa Queimadas do INPE.

Figura 31 - Distribuição espacial dos focos de queimadas no PEEA nos anos de 2023 e 2024, discriminados por mês de ocorrência, conforme dados do Programa Queimadas do INPE.



Fonte: Elaborado pela autora com dados do INPE (2025b).

Conforme ilustrado na Figura 31, diferentemente de 2020, quando os focos se concentraram em agosto e setembro, os registros ocorreram nos meses de outubro (110) e novembro (100) em 2023 e em setembro (43) e outubro (265) em 2024. Esse novo episódio reflete não apenas a sazonalidade típica do fogo no Pantanal, mas também os impactos crescentes dos eventos climáticos extremos, como secas prolongadas e aumento das temperaturas, cuja frequência tem se intensificado nos últimos anos.

4.3 Materiais

4.3.1 Imagens SAR/Sentinel-1

A missão Sentinel-1 integra o programa europeu Copernicus, coordenado pela Comissão Europeia e desenvolvido pela Agência Espacial Europeia (ESA). Trata-se de uma constelação de satélites equipados com Radar de Abertura Sintética (SAR), projetada

para fornecer acesso a grandes quantidades de dados de observação da Terra, gratuitos e contínuos, independentes das condições meteorológicas ou de iluminação.

Inicialmente composta pelos satélites Sentinel-1A e Sentinel-1B, lançados em 3 de abril de 2014 e 25 de abril de 2016, respectivamente, a missão foi projetada para operar com dois satélites em órbitas quase polares e sincronizadas com o Sol. Cada satélite possui um ciclo de repetição de 12 dias, totalizando 175 órbitas por ciclo. Quando em operação conjunta, esse intervalo é reduzido para 6 dias, com os satélites compartilhando o mesmo plano orbital, separados por uma diferença de fase de 180°, permitindo cobertura mais frequente e eficiente da superfície terrestre.

Em dezembro de 2021, o satélite Sentinel-1B sofreu uma falha elétrica que comprometeu permanentemente sua operação, levando à sua desativação oficial em 2022. Desde então, somente o Sentinel-1A permaneceu em funcionamento. Como parte do plano de recuperação da plena capacidade da missão, o Sentinel-1C foi lançado em dezembro de 2024 e o lançamento do Sentinel-1D está previsto para o segundo semestre de 2025, com o objetivo de substituir gradualmente o Sentinel-1A e assegurar a continuidade operacional da missão nos próximos anos.

Os satélites Sentinel-1 estão equipados com um instrumento SAR que opera na banda C, com frequência central de 5,404 GHz, e oferecem diferentes modos de polarização. No modo de polarização única, o sistema pode operar em HH (emissão e recepção na horizontal) ou VV (emissão e recepção na vertical). No modo de dupla polarização, denominado *cross-polarizado*, o sensor realiza a emissão em uma polarização e a recepção em ambas, resultando nas combinações HH+HV (emissão horizontal e recepção horizontal e vertical) ou VV+VH (emissão vertical e recepção vertical e horizontal).

Além disso, o sistema possui quatro modos distintos de aquisição: *Stripmap Mode* (SM), *Interferometric Wide Swath Mode* (IW), *Extra-Wide Swath Mode* (EW) e *Wave Mode* (WV). O IW é o principal modo de aquisição de dados do sistema sobre a superfície terrestre, atendendo à maioria das demandas operacionais dos serviços. Ele adquire imagens com faixa de varredura de 250 km e resolução espacial de 5 m por 20 m. A captura é realizada em três subfaixas por meio da técnica *Terrain Observation with Progressive Scans SAR* (TOPSAR), evitando descontinuidades entre cenas e resultando em qualidade de imagem homogênea em toda a faixa (ESA, 2025a).

Entre os produtos gerados pelos satélites Sentinel-1, destacam-se dois formatos principais: o *Single Look Complex* (SLC) e o *Ground Range Detected* (GRD). A principal

diferença entre eles é o nível de processamento e o tipo de informação preservada. O formato SLC mantém os dados complexos (amplitude e fase), preservando a resolução espacial nativa. Essa estrutura permite sua aplicação em técnicas que utilizam a informação de fase, como a interferometria SAR (InSAR), voltada à detecção de movimentos na superfície. Contudo, essas imagens exigem um pré-processamento mais extenso, incluindo etapas como *split*, *deburst* e *multilooking*.

Por outro lado, o formato GRD fornece imagens com a fase do sinal removida e geocodificadas em coordenadas aproximadas de terreno (*ground range*). Essas imagens são mais acessíveis para análises temáticas, como classificação de uso da terra, séries temporais e detecção de mudanças, uma vez que o produto GRD é fornecido com etapas de pré-processamento já incorporadas. Em contrapartida, essas imagens apresentam menor resolução espacial devido ao *multilooking* aplicado previamente.

Ambos os formatos requerem calibração radiométrica e correção do terreno para uma análise precisa. No entanto, o SLC é mais volumoso e tecnicamente exigente, enquanto o GRD oferece maior praticidade e menor tamanho de arquivo. A escolha entre SLC e GRD depende dos objetivos específicos da aplicação. As imagens podem ser adquiridas gratuitamente por meio do portal *Copernicus Browser* (<https://browser.dataspace.copernicus.eu/>).

A partir do processamento de dados SAR, é possível extrair diferentes produtos, como os coeficientes de retroespalhamento em diferentes polarizações e diversos índices polarimétricos, que fornecem informações valiosas sobre a interação do sinal de Radar com a superfície terrestre. Esses produtos refletem características físicas dos alvos, cujas propriedades, como o teor de umidade (relacionado à constante dielétrica), a rugosidade da superfície e a geometria estrutural, influenciam diretamente a intensidade do sinal refletido. No caso da vegetação, essas variáveis são particularmente relevantes para identificar padrões estruturais e alterações provocadas por distúrbios como o fogo.

Os sensores SAR têm se consolidado como ferramentas fundamentais no monitoramento e caracterização de diferentes formações vegetais, especialmente em ambientes naturais sujeitos a distúrbios como o fogo. Uma de suas principais vantagens em relação aos sensores ópticos é a capacidade de aquisição independente da iluminação solar e com baixa sensibilidade às condições atmosféricas, como cobertura de nuvens, neblina ou fumaça, fatores comuns em regiões tropicais e em cenários de queimadas. Essa característica permite a obtenção contínua de imagens ao longo do tempo, mesmo em

períodos chuvosos ou durante eventos extremos, favorecendo a construção de séries temporais mais consistentes e completas.

Além disso, a incorporação de dados SAR fortalece as análises ambientais, proporcionando informações complementares aos dados ópticos. Essa integração é essencial para o monitoramento em alta frequência temporal e com maior confiabilidade, especialmente em ecossistemas sujeitos a distúrbios recorrentes, como os incêndios florestais. Nesse contexto, a utilização de séries temporais consistentes é fundamental para acompanhar a dinâmica da vegetação, mesmo em condições meteorológicas adversas que podem limitar a aquisição de imagens ópticas.

4.3.2 Imagens multiespectrais ópticas Sentinel-2

A missão Copernicus Sentinel-2 é composta por uma constelação de dois satélites, Sentinel-2A e Sentinel-2B, lançados em 23 de junho de 2015 e 7 de março de 2017, respectivamente. Os satélites estão em órbita polar sincronizada com o Sol e separados por 180° entre si, ambos equipados com o sensor *MultiSpectral Instrument* (MSI) de imageamento multiespectral.

O objetivo principal da missão é monitorar a variabilidade das condições da superfície terrestre, oferecendo uma faixa orbital de 290 km. Com essa configuração, a missão proporciona uma revisita de dez dias ao longo do equador com um satélite e de cinco dias quando ambos os satélites estão operacionais. A cobertura da missão abrange latitudes entre 56° sul e 84° norte (ESA(b), 2025).

O Sentinel-2 possui resolução radiométrica de 12 bits e oferece 13 bandas espectrais espalhadas pelos domínios do visível, infravermelho próximo (NIR) e do infravermelho de ondas curtas (SWIR), com resoluções espaciais que variam de 10 a 60 m. A Tabela 4 apresenta os detalhes de cada uma dessas bandas, incluindo a resolução espacial, número, nome e o comprimento de onda central, expresso em nanômetros, para os dois satélites da constelação.

Tabela 4 - Bandas espectrais do Sentinel-2 e suas respectivas resoluções espaciais, número, nome e comprimentos de onda centrais.

Resolução espacial (m)	Número da banda	Nome da Banda	Comprimento de onda central da banda (nm)	
			S2A	S2B
10	2	Azul	492,4	492,1
	3	Verde	559,8	559
	4	Vermelho	664,6	664,9
	8	Infravermelho Próximo	832,8	832,9
20	5	Red Edge 1	704,1	703,8
	6	Red Edge 2	740,5	739,1
	7	Red Edge 3	782,8	779,7
	8A	Red Edge 4	864,7	864
	11	Infravermelho de Ondas Curtas 1	1613,7	1610,4
	12	Infravermelho de Ondas Curtas 2	2202,4	2185,7
60	1	Aerossol	442,7	442,2
	9	Water Vapor	945,1	943,2
	10	Cirrus	1373,5	1376,9

Fonte: ESA, 2025b

Os produtos Sentinel-2 estão disponíveis nos Níveis 1C e 2A, correspondendo, respectivamente, à reflectância no topo da atmosfera (*Top Of Atmosphere* - TOA) e à reflectância de superfície (*Bottom Of Atmosphere* - BOA). Ambos os níveis são fornecidos como ortoimagens de extensão de 100×100 km, na projeção UTM/WGS84, com correções radiométricas e geométricas aplicadas. Os dados podem ser acessados gratuitamente por meio do portal *Copernicus Browser* (<https://browser.dataspace.copernicus.eu/>).

Inicialmente, apenas os produtos de Nível 1C eram disponibilizados de forma sistemática. A partir de 2017, os produtos Sentinel-2 passaram a ser processados retroativamente para o Nível 2A utilizando o algoritmo Sen2Cor, e disponibilizados aos usuários. O Sen2Cor é um processador oficial, desenvolvido pela ESA, utilizado para realizar a correção atmosférica em imagens do Sentinel-2. Sua principal função é converter os dados de reflectância no topo da atmosfera (Nível 1C - TOA) para reflectância de superfície (Nível 2A - BOA), minimizando os efeitos causados pela atmosfera, como espalhamento e absorção, tornando as imagens mais precisas para análises ambientais e geoespaciais.

4.3.3 Dados do Projeto MapBiomias

Para o desenvolvimento desta tese, foram utilizados produtos gratuitos disponibilizados pelo Projeto MapBiomias, referentes à área de estudo no ano de 2020: a Coleção BETA, que fornece os tipos de uso e cobertura da terra, e a plataforma Monitor do Fogo, que apresenta mapeamentos mensais de áreas queimadas. Ambos os produtos possuem resolução espacial de 10 metros.

4.3.3.1 Mapbiomas Coleção BETA

O Projeto MapBiomias (<https://mapbiomas.org/>), iniciado em 2015 pelo Observatório do Clima em parceria com diversas instituições, tem como objetivo mapear anualmente a cobertura e o uso da terra no Brasil, acompanhando as transformações territoriais. A produção dos mapas é feita por uma equipe multidisciplinar, utilizando processamento em nuvem via *Google Earth Engine* (GEE). Os dados gerados são públicos, gratuitos e disponíveis para *download*, inclusive para uso comercial.

Desde o lançamento do projeto, o MapBiomias produziu nove coleções de mapas de uso e cobertura do solo com base em classificação pixel a pixel de imagens Landsat, de resolução espacial de 30 metros e algoritmos baseados em ML. Cada nova coleção refletiu ajustes no período coberto pelos mapas anuais, atualizações na legenda ou correções em relação às versões anteriores.


Em 2023, o Projeto MapBiomias lançou a Coleção Beta que oferece mapas anuais de uso e cobertura da terra no Brasil com resolução espacial de 10 metros, cobrindo o período de 2016 a 2022. Baseada na metodologia da Coleção 7.1 (Landsat, 30 m), a nova coleção adapta algoritmos para imagens Sentinel-2, mantendo a tipologia consolidada das classes (até o nível 3 da legenda). A maior resolução permite um mapeamento mais detalhado, especialmente em áreas sensíveis como margens de rios e nascentes. Apesar disso, a coleção ainda está em desenvolvimento e deverá ser aprimorada em versões futuras (Projeto Mapbiomas – Coleção Beta, 2025).

A metodologia da Coleção 7.1 inicia com a geração de mosaicos anuais que cobrem todo o Brasil, utilizando imagens Landsat de 30 metros de resolução espacial, disponíveis gratuitamente na plataforma GEE. Com base nos mosaicos de imagens, são desenvolvidos mapas individuais representando diferentes tipos de cobertura e uso da terra, como florestas, áreas agrícolas, pastagens, zonas urbanas e corpos d'água. Esse

processo utiliza o classificador baseado em ML RF. O algoritmo é treinado com amostras representativas dos elementos a serem identificados. A classificação é realizada anualmente, consolidando mapas específicos para cada classe, nos quais cada pixel armazena múltiplas camadas de informação referentes aos anos considerados na série histórica.

A Figura 32 ilustra a distribuição espacial dos tipos de uso e cobertura no Pantanal em 2020, ano central desta pesquisa devido aos eventos extremos de queimadas registrados.

Figura 32 - Distribuição espacial dos tipos de uso e cobertura da terra no bioma Pantanal em 2020, conforme dados da Coleção Beta 10 metros do MapBiomas.



Fonte: Elaborado pela autora com dados do Projeto MapBiomas – Coleção Beta (2025)

Como evidenciado na Figura 32, as formações campestres e savânicas predominam na região, ocupando 36,00% e 24,41% da área total, respectivamente. Em seguida, destacam-se as áreas de pastagem (19,87%), formação florestal (11,41%), áreas alagadas e pantanosas (4,20%) e corpos hídricos como rios e lagos (3,95%), refletindo a diversidade de cobertura presente e que são característicos da dinâmica sazonal do Pantanal. As demais classes, como silvicultura, mineração e uso urbano, possuem

representação reduzida, indicando baixa intensidade de ocupação antrópica direta nessas categorias específicas. Os dados da Coleção Beta 10 metros estão disponíveis na plataforma GEE e podem ser acessadas por meio do *asset ID* da coleção: <https://code.earthengine.google.com/1fa498f7e5e7d689b10e0e121abf4e51>.


A Quadro 1 apresenta a descrição detalhada dos tipos de uso e cobertura do solo presentes na área estudo, o PEEA, extraídos da Coleção 7.1 do MapBiomas, à qual a Coleção Beta – 10 m está associada. A Figura 33 detalha as classes de uso e cobertura específicas da UC, com base na Coleção Beta para o ano de 2020, marcado por um intenso período de estiagem e severos episódios de queimadas.

Quadro 1 - Descrição detalhada dos tipos de uso e cobertura da terra da Coleção 7.1 do MapBiomas (à que se refere a coleção BETA – 10 m) para o PEEA inserido no bioma Pantanal.

Nível 1	Nível 2	Descrição breve
Floresta	Formação Florestal	Árvores altas e arbustos no estrato inferior: Floresta Estacional Decidual e Semidecidual, Savana Florestada, Savana-Estépica Florestada e Formações Pioneiras com influência fluvial e/ou lacustre.
	Formação Savânica	Espécies arbóreas de pequeno porte, distribuídas de forma esparsa e dispostas em meio à vegetação contínua de porte arbustivo e herbáceo. A vegetação herbácea se mistura com arbustos eretos e decumbentes.
Formação Natural não Florestal	Campo Alagado e Área Pantanosa	Vegetação herbácea com predomínio de gramíneas sujeitas ao alagamento permanente ou temporário (pelo menos uma vez ao ano) de acordo com os pulsos naturais de inundação. O elemento lenhoso pode estar presente sobre a matriz campestre formando um mosaico com plantas arbustivas ou arbóreas (ex: cambarazal, paratudal e carandazal). As áreas pantanosas ocorrem geralmente nas margens das lagoas temporárias ou permanentes ocupadas por plantas aquáticas emergentes, submersas ou flutuantes (ex: brejos e baceiros). Áreas com superfície de água, mas de difícil classificação devido a quantidade de macrófitas, eutrofização ou sedimentos, também foram incluídas nesta categoria.
	Formação Campestre	Vegetação com predomínio de estrato herbáceo graminóide, com presença de arbustivas isoladas e lenhosas raquíticas. A composição botânica é influenciada pelos gradientes edáficos e topográficos e pelo manejo pastoril (pecuária). Manchas de vegetação exótica invasora ou de uso forrageiro (pastagem plantada) podem estar presentes formando mosaicos com a vegetação nativa.
Corpos d'água	Rio, Lago e Oceano	Rios, lagos, represas, reservatórios e outros corpos d'água.

Fonte: Projeto MapBiomas (2025)

Figura 33 - Mapa de uso e cobertura da terra do PEEA para o ano de 2020, conforme a Coleção Beta 10 metros do Projeto MapBiomas.



Fonte: Elaborado pela autora com dados do Projeto MapBiomas – Coleção Beta (2025)

De acordo com a classificação de tipos de uso e cobertura do solo do Projeto MapBiomas - Coleção Beta 10 metros referente ao PEEA no ano de 2020 (Figura 33), as classes identificadas incluem Formação Campestre (FC), Formação Florestal (FF) e Formação Savânica (FS), que correspondem, respectivamente, a 35,5% (em torno de 384 km²), 31,4% (340 km²) e 25,9% (280 km²) da área total, compondo a maior parte da paisagem do parque. Outras classes mapeadas incluem Campo Alagado e Área Pantanosa (CAAP), com 4,7% (50 km²), corpos d'água classificados como Rio, Lago ou Oceano (RLO), com 1,7% (18 km²), e Pastagem (P), que ocupa 0,8% (9 km²) da área. Esses dados evidenciam a predominância de formações naturais no território do PEEA, com destaque para os ambientes campestres, florestais e savânicos.

Além da descrição e da análise da distribuição espacial dos tipos de uso e cobertura da terra no PEEA, realizadas anteriormente, o Quadro 2 apresenta a caracterização visual das diferentes classes mapeadas na paisagem da UC. Para isso, são utilizadas fotografias que exemplificam cada uma das classes, extraídas da Chave de Interpretação Visual, desenvolvida pelo Laboratório de Processamento de Imagens e Geoprocessamento – LAPIG (LAPIG, 2025).

Quadro 2 - Fotografias referentes às classes de uso e cobertura no PEEA, conforme a Chave de Interpretação Visual do Laboratório de Processamento de Imagens e Geoprocessamento - LAPIG (LAPIG, 2025).

Formação Florestal (FF)	Formação Savânica (FS)
	
Campo Alagado e Área Pantanosa (CAAP)	Formação Campestre (FC)
	
Rio, Lago e Oceano (RLO)	
	

Fonte: LAPIG (2025)

4.3.3.2 MapBiomas Monitor do Fogo

O Monitor do Fogo do MapBiomas (Projeto Mapbiomas - Monitor do Fogo, 2025) representa a primeira versão do mapeamento mensal de áreas queimadas no Brasil, abrangendo dados a partir de 2019 com resolução espacial de 10 m. Desenvolvido em colaboração com instituições da rede MapBiomas, o projeto se baseia em mosaicos mensais de imagens multiespectrais do Sentinel-2, e utiliza algoritmos de aprendizado profundo e computação em nuvem por meio do GEE e do *Google Cloud Storage*. A

classificação foi estruturada por biomas e regiões, com a coleta de amostras para treinar o modelo de detecção de áreas queimadas e não queimadas, seguindo a metodologia descrita por Alencar *et al.* (2022).

Em uma visão geral, o processo de mapeamento seguiu seis etapas principais: definição das áreas de classificação conforme os biomas, geração de mosaicos mensais com base em imagens do Sentinel-2, seleção de amostras espectrais de áreas queimadas e não queimadas para treinamento do modelo, treinamento do modelo baseado em redes neurais profundas (DNN - *Deep Neural Network*), aplicação de filtros para correção de inconsistências pós-classificação e, por fim, validação dos resultados.


A delimitação das áreas analisadas pelo Projeto MapBiomas Monitor do Fogo foi estabelecida com um *buffer* de 5 km ao redor dos focos de calor identificados pelo INPE. Os mosaicos mensais foram construídos com base no índice espectral NBR derivado das imagens disponíveis de cada mês, após a remoção dos ruídos de nuvens.

O modelo de classificação empregado foi uma DNN, configurada no formato *Multi-Layer Perceptron Network* (MLPN). Como variáveis de entrada, foram utilizadas as bandas espectrais Red, NIR, SWIR1 e SWIR2, enquanto a saída do modelo categoriza as áreas como queimadas ou não queimadas. No pós-processamento são aplicadas máscaras para redução de eventuais erros de comissão, considerando critérios específicos para cada bioma.

Os dados do MapBiomas - Monitor do Fogo podem ser acessados no endereço eletrônico da plataforma do Monitor do Fogo: <https://plataforma.brasil.mapbiomas.org/monitor-do-fogo>, ou por meio do *asset* ID do GEE: https://code.earthengine.google.com/?accept_repo=users%2Fmapbiomas%2Fuser-toolkit&scriptPath=users%2Fmapbiomas%2Fuser-toolkit%3Amapbiomas-user-toolkit-fire.js.

A Figura 34 apresenta a distribuição espacial das áreas queimadas no PEEA, discriminada por mês, para o período de agosto a novembro de 2020, intervalo caracterizado por condições climáticas extremas e queimadas de grande magnitude, conforme considerado neste estudo.

Figura 34 - Distribuição espacial das áreas queimadas no PEEA, separadas por meses de registro (agosto, setembro, outubro e novembro) em 2020, conforme o Monitor do Fogo.



Fonte: Elaborado pela autora com dados do Projeto MapBiomas - Monitor do Fogo (2025)

A distribuição espacial das áreas queimadas no PEEA, conforme ilustrado na Figura 34, evidencia a concentração dos focos de queimadas durante os meses mais críticos de 2020. A análise mensal revela que setembro foi o mês com maior incidência de queimadas, representando 87,8% da área total afetada no período, o que corresponde a aproximadamente 443,48 km². Em outubro, foram queimados cerca de 49,62 km², o equivalente a 9,8% da área total queimada. Os meses de agosto e novembro apresentaram valores significativamente menores, com queimadas em torno de 8,65 km² (1,7%) e 3,25 km² (0,6%), respectivamente. Esses dados reforçam a severidade do impacto das queimadas em setembro, coincidindo com as condições climáticas extremas registradas na região. Meses com áreas queimadas inferiores a 2,00 km² não foram considerados neste estudo.

4.3.4 Dados meteorológicos

4.3.4.1 Precipitação


O Portal HydroWeb, integrante do Sistema Nacional de Informações sobre Recursos Hídricos (SNIRH), disponibiliza dados históricos coletados pela Rede Hidrometeorológica Nacional (RHN) sobre níveis fluviais, vazões, chuvas, qualidade da água e sedimentos. Essas informações são essenciais para a gestão hídrica e setores como energia, irrigação, navegação e infraestrutura hidráulica.

A Agência Nacional de Águas (ANA) coordena a RHN, que conta com mais de 23 mil estações pluviométricas e fluviométricas. A ANA mantém cerca de 4.700 dessas estações e publica os dados coletados por parceiros federais, setoriais, estaduais e privados. O monitoramento é realizado por entidades como o Serviço Geológico do Brasil (SGB), a Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina (EPAGRI/SC), o Departamento de Águas e Energia Elétrica de São Paulo (DAEE/SP), o Instituto Mineiro de Gestão das Águas (IGAM/MG), o Instituto Água e Terra do Paraná (IAT/PR) e empresas contratadas (ANA, 2025).

O histórico do monitoramento das águas no Brasil tem suas origens no século XIX, e a responsabilidade pela sua coordenação passou para a ANA em 2000. Além do acompanhamento de eventos críticos, os dados permitem simulações e previsões hidrológicas.

Para este estudo, foram adquiridos dados históricos de precipitação provenientes da estação pluviométrica Ilha Camargo, no período de janeiro de 2019 a setembro de 2024, sendo este o último mês com dados disponíveis no momento da coleta. A estação está localizada no município de Barão de Melgaço – MT (Latitude: -17.0572, Longitude: -56.5856), próxima à área de estudo (Figura 35). O início de operações da estação ocorreu em 1968 e atualmente é operada pelo SGB (anteriormente conhecido como Companhia de Pesquisa de Recursos Minerais - CPRM), sob responsabilidade da ANA.

Figura 35 - Localização da estação pluviométrica Ilha Camargo de responsabilidade da ANA, operada por SGB-CPRM, em relação à área de estudo.



Fonte: <https://www.snirh.gov.br/hidroweb/mapa>

Os dados de precipitação da estação pluviométrica Ilha Camargo são disponibilizados em médias mensais. Essas informações são fundamentais para a compreensão da influência dos regimes de chuva sobre a dinâmica do fogo no PEEA, especialmente no que se refere à sazonalidade das queimadas. A análise desses dados permite relacionar períodos de estiagem prolongada com a maior ocorrência de incêndios florestais, bem como avaliar os efeitos das variações pluviométricas sobre a regeneração da vegetação e a vulnerabilidade das diferentes classes de uso e cobertura do solo ao fogo ao longo do tempo.

Além disso, busca-se estabelecer correlações entre os padrões de precipitação e os parâmetros extraídos de sensores de Radar, a fim de compreender como a umidade do solo e a estrutura da vegetação respondem a eventos extremos. A integração desses dados contribui para a caracterização de áreas mais suscetíveis ao fogo e permite uma compreensão mais aprofundada dos fatores ambientais que influenciam a frequência e a distribuição espacial das queimadas.

4.3.4.2 Temperatura

O *MODerate Resolution Imaging Spectroradiometer* (MODIS) é um sensor óptico desenvolvido pela *National Aeronautics and Space Administration* (NASA), como parte do programa *Earth Observing System* (EOS). Ele foi lançado em órbita terrestre a

bordo do satélite Terra (EOS-AM) em 1999 e do satélite Aqua (EOS-PM) em 2002 (MODIS, 2025).

O MODIS opera em um intervalo espectral de 0,4 a 14,4 micrômetros, abrangendo 32 bandas espectrais, com resoluções espaciais de 250 m, 500 m e 1.000 m, dependendo da banda. Esse instrumento possui ampla aplicação no monitoramento ambiental, fornecendo dados de alta frequência temporal e cobertura global. Mais informações técnicas podem ser acessadas no site oficial do programa: <https://modis.gsfc.nasa.gov/>.

Entre os diversos conjuntos de observações disponibilizadas pelo sensor MODIS, destaca-se a série *Land Surface Temperature and Emissivity* (LST&E), que fornece estimativas da temperatura da superfície terrestre e emissividade em diferentes comprimentos de onda do espectro infravermelho térmico.

Dentro desse contexto, o conjunto de dados MYD21C3 representa uma composição mensal global derivada de observações diárias do sensor MODIS a bordo do satélite Aqua, com resolução espacial de 0,05 graus (~5,6 km na linha do equador), cobrindo a superfície terrestre globalmente. As medições se baseiam em três bandas espectrais na região do infravermelho termal: Banda 29 (com comprimento de onda entre 8,4 e 8,7 μm), Banda 31 (10,8 a 11,3 μm) e Banda 32 (11,8 a 12,3 μm) (HULLEY; HOOK, 2021).

A coleção *MYD21C3 v061 – MODIS/Aqua Land Surface Temperature/3-Band Emissivity Monthly L3 Global 0.05 Deg CMG* está disponível na plataforma GEE e pode ser acessada por meio da expressão `ee.ImageCollection("MODIS/061/MYD21C3")`. A versão v061 indica a atualização mais recente do algoritmo de processamento, que incorpora melhorias na calibração radiométrica, correções atmosféricas e modelos de emissividade. Os dados estão disponíveis na plataforma no intervalo temporal de fevereiro de 2000 a fevereiro de 2025, abrangendo mais de duas décadas de observações contínuas da temperatura da superfície terrestre e emissividade.

No presente estudo, será utilizada a variável *LST_Day*, disponibilizada pelo produto MYD21C3 v061 na plataforma GEE, a qual representa a temperatura da superfície terrestre, expressa em Kelvin (K), e estimada a partir de observações realizadas durante o período diurno. Essa variável será empregada na construção de uma série temporal voltada ao monitoramento da dinâmica térmica da área de estudo no período de janeiro de 2019 a dezembro de 2024. A análise tem como propósito identificar possíveis relações entre as variações da temperatura da superfície terrestre e a ocorrência de

queimadas, em associação com dados provenientes de sensores SAR, contribuindo para uma compreensão mais aprofundada dos fatores ambientais que influenciam sua frequência e distribuição espacial.

4.3.5 Ferramentas Computacionais

As ferramentas utilizadas para o desenvolvimento da pesquisa foram os *softwares Sentinel Application Platform 11.0 (SNAP)*, *ArcGIS Pro 3.4.0*, a implementação em JavaScript no Ambiente de Desenvolvimento Integrado (*Integrated Development Environment - IDE*) da plataforma *Google Earth Engine (GEE)* e implementações em Python e R realizadas nos IDEs *Spyder* e *RStudio*, respectivamente, ambos executados no ambiente *Anaconda*.

SNAP:

O SNAP é um *software* gratuito desenvolvido pela ESA, voltado para o processamento de dados de sensoriamento remoto e oferece um conjunto de ferramentas integradas para a manipulação e análise de dados, especialmente dos satélites Sentinel. Além disso, também é compatível com dados de outros sensores, como Landsat, MODIS e Envisat. O *software* permite a correção atmosférica, calibração radiométrica, filtragem, fusão de imagens, entre outras operações essenciais para análises ambientais.

Na presente pesquisa, o sistema foi utilizado para o processamento de imagens Sentinel-1 e 2 e cálculo de índices espectrais e polarimétricos, de alguns experimentos. O SNAP está disponível para *download* na página oficial: <http://step.esa.int/main/download/>, e tutoriais para diversas aplicações podem ser acessados em: <https://step.esa.int/main/doc/tutorials/>.

ArcGIS:

O ArcGIS Pro é um *software* de Sistema de Informação Geográfica (SIG) desenvolvido pela *Environmental Systems Research Institute (Esri)*. O *software* oferece ferramentas avançadas para análise espacial, modelagem, manipulação de dados geográficos e criação de mapas de alta qualidade.

O ArcGIS Pro é um *software* proprietário de acesso restrito, utilizado nesta pesquisa para a coleta de amostras de treinamento das classes de interesse e para geração

de mapas temáticos, por meio de uma licença de estudante fornecida pela Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP).

Linguagem Python:

Python é uma linguagem de programação de alto nível, criada por Guido Van Rossum no início da década de 1990 (GUIDO VAN ROSSUM, 2018). Projetada para facilitar a legibilidade do código, possui uma sintaxe concisa e uma biblioteca padrão extensa. A linguagem desempenha um papel essencial para a ciência de dados, sendo amplamente utilizada na realização de cálculos estatísticos avançados, visualizações de dados, desenvolvimento de algoritmos baseados em ML e DL, além de manipulação e análise de grandes volumes de informações.

Para isso, destaca-se o uso de bibliotecas como TensorFlow, Keras e segmentation-models, que são ferramentas fundamentais para o desenvolvimento e aplicação de modelos e técnicas avançadas em inteligência artificial. A biblioteca TensorFlow, que foi desenvolvida para ser utilizada principalmente em Python, facilita o desenvolvimento, treinamento e implementação de modelos de ML. O Keras, por sua vez, funciona como uma interface de alto nível para o TensorFlow, simplificando o desenvolvimento de modelos e permitindo uma implementação mais eficiente.

A biblioteca segmentation-models é utilizada para segmentação de imagens, contribuindo para a identificação e a classificação de elementos em dados geoespaciais, auxiliando em diversas aplicações de sensoriamento remoto e análise territorial. Essa biblioteca utiliza o Keras para a construção das arquiteturas de rede neural, enquanto o Keras emprega o TensorFlow como *backend* para a execução das operações computacionais.

Nesta pesquisa, a linguagem Python foi utilizada por meio da IDE Spyder (*Scientific Python Development Environment*), um ambiente integrado voltado para aplicações científicas que inclui editor de código, console interativo e visualizador de variáveis. O Spyder foi acessado por meio da distribuição Anaconda, uma plataforma *open source* que reúne ferramentas, bibliotecas e ambientes voltados à ciência de dados, aprendizado de máquina e análise estatística, facilitando o gerenciamento de pacotes e ambientes em Python.

Com base nas ferramentas, bibliotecas e ambientes descritos, como a linguagem Python, suas bibliotecas especializadas, e a IDE *Spyder* na distribuição Anaconda, foram desenvolvidas diversas atividades fundamentais para esta pesquisa. Dentre elas, destaca-

se a implementação da rotina de uma rede de segmentação semântica baseada em DL, utilizando a arquitetura U-Net, além da realização de todos os pré-processamentos necessários para preparar os dados de entrada da rede. Também foram gerados gráficos de séries temporais representando diferentes tipos de uso e cobertura do solo, integrando dados de precipitação e temperatura, os quais contribuíram para a análise e interpretação da dinâmica temporal da área de estudo.

Plataforma GEE:

O GEE é uma plataforma desenvolvida para o processamento e análise avançada de dados geoespaciais em nuvem. A infraestrutura do sistema integra um extenso catálogo de imagens de satélite e dados geoespaciais, tanto atuais quanto históricos, juntamente com poderosas ferramentas de análise. Além disso, a interface online da plataforma permite a implementação de algoritmos em JavaScript, com acesso a um vasto catálogo de imagens de satélite e dados climáticos, o que amplia significativamente as possibilidades de análise.

Ao integrar o processamento em nuvem, o GEE potencializa a análise e visualização de dados ambientais, tornando-se uma ferramenta essencial para a investigação das dinâmicas do planeta, como as mudanças climáticas e outros fenômenos naturais, além de contribuir significativamente para a eficiência no trabalho e redução do tempo de processamento. Mais detalhes sobre a plataforma podem ser acessados em: <https://earthengine.google.com>.

No GEE, os dados do Sentinel-1 estão disponíveis por meio da coleção “COPERNICUS/S1_GRD”, composta por imagens no formato GRD. Já as imagens ópticas do Sentinel-2 podem ser acessadas nas seguintes coleções: “COPERNICUS/S2_HARMONIZED”, que fornece bandas espectrais em refletância no topo da atmosfera (Nível 1C) e “COPERNICUS/S2_SR_HARMONIZED”, que oferece produtos corrigidos para refletância de superfície (*Surface Reflectance* – SR, Nível 2A). Ambos os níveis disponibilizam imagens ortorretificadas.

As coleções Sentinel disponíveis no GEE cobrem diferentes períodos de aquisição. As imagens ópticas do Sentinel-2 de Nível-1C estão disponíveis a partir de 2015, enquanto os produtos de Nível-2A, de 2017 até o presente. A coleção do Sentinel-1, por sua vez, oferece imagens desde 2014 até o momento. Novos dados são incorporados a essas coleções em até dois dias após sua liberação oficial. Vale destacar que tanto o

período de disponibilidade quanto a frequência de revisita das imagens podem variar conforme a região geográfica (SENTINEL COLLECTIONS, 2025).

O GEE foi empregado nesta pesquisa para diversas tarefas, incluindo a classificação de áreas queimadas na área de estudo utilizando algoritmos baseados em ML: RF, CART, SVM e KNN. As métricas de acurácia da classificação, como matriz de confusão, *F-Score*, e Acurácia Global (AG), também foram calculadas diretamente na plataforma, permitindo avaliar o desempenho dos diferentes modelos aplicados.

A matriz de confusão é uma tabela utilizada para avaliar o desempenho de classificações por meio da comparação entre os dados classificados e os dados de referência. Ela organiza as classes em linhas e colunas, permitindo identificar acertos e erros de classificação. A AG corresponde à razão entre o número total de pixels corretamente classificados e o total de pixels avaliados na matriz de confusão, expressando a proporção de elementos corretamente classificados (CONGALTON, 1991).

A medida *F-Score* é a média harmônica de *Precision* (confiança) e *Recall* (sensibilidade). *Precision* descreve a proporção de casos positivos identificados corretamente ou não. *Recall* é a proporção de casos positivos e negativos identificados corretamente. O *F-Score* atinge seu melhor valor em 1 (*Precision* e *Recall* perfeitos) (POWERS, 2008).

Adicionalmente, a plataforma GEE foi utilizada para a geração de séries temporais com imagens dos sensores Sentinel-1 e Sentinel-2, bem como para o cálculo da separabilidade espectral entre as respostas dos pixels em áreas queimadas e não queimadas, com base em amostras representativas extraídas de diferentes índices polarimétricos.

Linguagem R:

R é uma linguagem de programação voltada para a análise estatística e visualização de dados, amplamente empregada nos campos de estatística aplicada e ciência de dados (R DEVELOPMENT CORE TEAM, 2025). Sua estrutura permite o desenvolvimento de análises complexas, com uma ampla variedade de pacotes voltados à manipulação, modelagem e representação gráfica de dados.

O R pode ser utilizado por meio do IDE RStudio, um ambiente desenvolvimento integrado especificamente para a linguagem, que permite a escrita, execução e organização do código de forma mais clara e eficiente. Essa interface facilita a realização

de análises quantitativas, tornando o processo mais acessível e produtivo. Além disso, tanto o R quanto o RStudio podem ser integrados ao Anaconda, uma plataforma que auxilia no gerenciamento de pacotes e ambientes virtuais, contribuindo para a organização e reprodutibilidade das análises.

No presente trabalho, o *software* estatístico R foi utilizado, por meio da IDE RStudio, para a geração e análise de séries temporais, com o uso da biblioteca *bfast* para a detecção e modelagem das mudanças temporais, contribuindo de forma significativa para o tratamento, organização e interpretação dos dados.

4.4 Metodologia

Para avaliar o potencial de atributos polarimétricos extraídos de dados SAR do sensor Sentinel-1 na detecção, mapeamento e monitoramento das alterações provocadas pelo fogo em diferentes classes de uso e cobertura da terra no PEEA, foram adotados uma série de procedimentos, considerando os objetivos específicos delineados (Quadro 3).


Quadro 3 - Síntese dos procedimentos gerais adotados em função dos objetivos específicos.

Aspectos investigados	Abordagem	Descrição
Avaliar o potencial de atributos polarimétricos SAR na detecção de áreas queimadas.	Utilização de imagens pré e pós-fogo dos coeficientes de retroespalhamento σ_{VH}^0 e σ_{VV}^0 SAR e do índice espectral NBR.	subseção 4.4.2
Avaliar o potencial de atributos polarimétricos SAR na detecção de áreas queimadas utilizando algoritmo baseado em DL, comparando com abordagens consolidadas usando dados ópticos.	Aplicação da rede neural de segmentação semântica U-Net na detecção de áreas queimadas em imagens SAR e óptica.	subseção 4.4.3
Analisar o impacto das queimadas sobre os diferentes tipos de uso e cobertura da terra do PEEA, a partir de dados SAR.	Mapeamento de áreas queimadas nos diferentes tipos de uso cobertura da terra, a partir de imagens-diferença SAR pré e pós-fogo, utilizando algoritmos ML (RF, KNN, SVM e CART).	subseção 4.4.4
Caracterizar o comportamento temporal da vegetação e do uso e cobertura da terra do PEEA, e monitorar a ocorrência de queimadas e a regeneração da vegetação do parque, utilizando dados SAR.	- Análise de séries temporais de atributos SAR, índices espectrais e dados meteorológicos. - Análise das correlações entre índices ópticos e parâmetros SAR. - Análise das séries temporais com algoritmo BFAST.	subseção 4.4.5

As abordagens relacionadas no Quadro 3 foram desenvolvidas utilizando imagens SAR e ópticas tratadas de acordo com os requisitos específicos para cada tipo de dado. Os pré-processamentos aplicados aos dados SAR e ópticos são apresentados no subitem 4.4.1, assim como os atributos derivados de cada tipo de imagem: índices polarimétricos calculados com base nos coeficientes de retroespalhamento sigma zero (σ^0) nas polarizações VH e VV (σ_{VH}^0 e σ_{VV}^0) e índices espectrais derivados de imagens ópticas.

4.4.1 Pré-processamento das imagens SAR e ópticas e geração de índices polarimétricos e espectrais

Foram utilizadas imagens SAR do sensor Sentinel-1 nos formatos SLC e GRD, ambos no modo de aquisição IW. Para a extração de σ_{VH}^0 e σ_{VV}^0 , foi seguido um conjunto de etapas de pré-processamento aplicadas às imagens em ambos os formatos, essenciais para garantir a consistência radiométrica e geométrica dos dados. A Figura 36 apresenta o fluxograma geral dessas etapas.



Fonte: Elaborado pela autora.

Conforme ilustrado na Figura 36, o pré-processamento das imagens SLC envolveu uma sequência de procedimentos fundamentais. Inicialmente, foi realizado o *Split* da imagem, etapa em que são selecionadas as sub-faixas (*sub-swaths*) e os *bursts* necessários para abranger a área de estudo. Em seguida, foi feita a correção da órbita com a atualização das informações orbitais contidas nos metadados do produto. Posteriormente, foi feita a remoção do ruído termal, garantindo que o valor de σ^0 reflita mais fielmente as características físicas da superfície observada.

Na sequência, foi realizada a calibração radiométrica dos dados, processo no qual os valores de número digital dos pixels são convertidos em valores de

retroespalhamento calibrado, como o sigma zero. Após essa etapa, foi aplicado o procedimento de *deburst*, que consiste na geração de uma imagem contínua por meio da eliminação das linhas de separação entre os *bursts* e *sub-faixas*. Em seguida, foi realizado o processamento *multilooking*, com o objetivo de reduzir o ruído *speckle* da imagem, definindo-se o número de looks nas direções de alcance e azimuth. Na etapa posterior, foi aplicado um filtro para suavização adicional da imagem. Por fim, foi realizada a correção do terreno, utilizando o modelo digital de elevação da missão SRTM de 30 metros de resolução, a fim de compensar deformações topográficas e obter os coeficientes de retroespalhamento sigma zero nas polarizações VV e VH (σ_{VV}^0 e σ_{VH}^0) corrigidos.

A obtenção dos coeficientes de retroespalhamento com base nas imagens no formato GRD foi realizada por meio da seguinte sequência de etapas de pré-processamento (Figura 36): correção orbital, remoção do ruído termal, calibração radiométrica, aplicação de filtro e, por fim, correção do terreno utilizando o modelo digital de elevação do SRTM.

Por se tratar de um produto disponibilizado ao usuário já submetido a certo nível de pré-processamento, as imagens GRD dispensam algumas etapas necessárias no tratamento das imagens SLC. Contudo, a aplicação de algumas etapas ainda é essencial, como as apresentadas na Figura 36. Todo o pré-processamento das imagens SAR adquiridas manualmente, tanto no formato SLC quanto no GRD, foi realizado no *software* SNAP, versão 8.0, desenvolvido pela ESA.

As imagens Sentinel-1 utilizadas para a geração das séries temporais não foram adquiridas manualmente, mas acessadas diretamente na nuvem por meio da plataforma GEE. No GEE, os dados do Sentinel-1 estão disponíveis através da coleção “COPERNICUS/S1_GRD”, que reúne cenas no formato GRD. Essas imagens são processadas com a ferramenta Sentinel-1 *Toolbox*, para gerar produtos calibrados e corrigidos geometricamente, prontos para análise.

O pré-processamento aplicado às imagens disponibilizadas na plataforma inclui a remoção do ruído térmico, a calibração radiométrica e a correção de terreno com base no modelo digital de elevação (MDE) SRTM. A aplicação do modelo SRTM permite reduzir distorções geométricas associadas à topografia nas imagens SAR, decorrentes da geometria de aquisição lateral do sensor. Embora sua resolução possa diferir da resolução espacial da imagem, modelos como o SRTM são amplamente utilizados em fluxos de processamento de Radar e fornecem estimativas adequadas da geometria do relevo para a correção radiométrica e geométrica das imagens (SMALL, 2011; DALPONTE;

MARINELLI; SOLANO-CORREA, 2024). Após essas correções, os valores de retroespalhamento são convertidos para decibéis (dB) por meio de uma escala logarítmica ($10 * \log_{10}(x)$).

A partir dos coeficientes de retroespalhamento SAR corrigidos, foram calculados os índices polarimétricos CR, RVI, DPSVI, NRPB, DPDD e PA, conforme apresentados na Tabela 3. A utilização desses índices tem como objetivo caracterizar diferentes tipos de uso e cobertura do solo, permitindo uma análise mais detalhada das variações espaciais e temporais observadas na área de estudo. Além disso, foi calculada a diferença entre os períodos pré e pós-fogo, tanto para os coeficientes de retroespalhamento σ_{VV}^0 e σ_{VH}^0 , quanto para os índices polarimétricos mencionados, denominados dVV, dVH, dCR, dRVI, dDPSVI, dNRPB, dDPDD e dPA, respectivamente.

Os índices polarimétricos apresentados na Tabela 3, bem como as diferenças entre os períodos pré e pós-fogo desses índices, foram utilizados ao longo do desenvolvimento dos diferentes experimentos realizados nesta pesquisa. Esses parâmetros contribuíram para a avaliação das alterações na superfície causadas pelas queimadas, fornecendo subsídios para a caracterização das áreas impactadas, considerando a resposta polarimétrica das imagens SAR.

As imagens ópticas do Sentinel-2 correspondem a produtos em reflectância de superfície (BOA), já corrigidos atmosférica e radiometricamente (Nível 2A), dispensando processamento adicional. As únicas etapas realizadas foram o recorte das cenas para a área de estudo e a reamostragem espacial, conforme os objetivos específicos de cada experimento.

Da mesma forma, as imagens Sentinel-2 utilizadas na construção das séries temporais acessadas por meio da plataforma GEE, estão disponíveis em reflectância de superfície. Nesta pesquisa, foram utilizadas imagens da coleção COPERNICUS/S2_SR_HARMONIZED, que disponibiliza produtos já corrigidos atmosféricamente (BOA, Nível 2A), cobrindo todo o período necessário para a geração das séries temporais.

Utilizando as imagens ópticas do sensor Sentinel-2, foram calculados os índices espectrais NDVI, NBR e NDWI (Tabela 1). O índice NDWI foi empregado na geração de máscaras de água, com o objetivo de remover essas feições para análises posteriores. (MCFEETERS, 1996). O NDVI foi utilizado como suporte à análise da dinâmica dos tipos de uso e cobertura do solo do PEEA, por meio da construção de séries temporais. O

NBR, por sua vez, foi aplicado tanto no mapeamento quanto no monitoramento de áreas afetadas por queimadas.

Para aprofundar a análise dessas áreas, foi utilizado o *Differenced Normalized Burn Ratio* (dNBR), índice derivado do NBR que permite avaliar tanto a extensão quanto a gravidade dos impactos causados pelo fogo. O dNBR é calculado pela diferença entre os valores de NBR obtidos nas imagens ópticas anteriores e posteriores ao evento de queimada, como apresentado na Equação 8.

$$dNBR = NBR_{pré-fogo} - NBR_{pós-fogo} \quad (8)$$


Como as áreas queimadas tendem a apresentar valores mais baixos no índice óptico NBR, elas assumem tons mais escuros nas imagens pós-fogo em comparação às imagens pré-fogo. Com base nessa diferença, o índice dNBR permite realçar as regiões afetadas pelo fogo, evidenciando-as em tons mais claros e facilitando sua detecção. Além disso, a sensibilidade do dNBR às variações na umidade do solo e na perda de vegetação verde, torna esse índice uma ferramenta eficaz para indicar a severidade dos impactos sobre a superfície terrestre (MILLER; THODE, 2007; ALLEN; SORBEL, 2008).

4.4.2 Análise do potencial dos atributos SAR na detecção de áreas queimadas

A abordagem concebida e aplicada para analisar o desempenho dos atributos SAR na detecção das áreas queimadas na área de estudos foi objeto de publicação no periódico *Bulletin of Geodetic Sciences* (BCG), no artigo intitulado “*Contribution of SAR/Sentinel-1 images in the detection of burnt areas in the natural vegetation of the brazilian Pantanal biome*” na *SPECIAL SECTION - Brazilian Colloquiums on Geodetic Sciences* em 2024.

O estudo foi conduzido no PEEA durante o período de incêndios florestais intensos de 2020, com o objetivo de avaliar o potencial dos dados SAR na detecção de áreas queimadas, por meio de classificação utilizando o algoritmo baseado em ML RF. O fluxograma geral da metodologia aplicada no estudo pode ser visto na Figura 37.

Figura 37 - Fluxograma geral da metodologia aplicada no experimento, onde $NBR_{pré}$ e $NBR_{pós}$ se referem ao índice espectral óptico Normalized Burn Ratio pré e pós-fogo, respectivamente, $dNBR$ se refere à diferença entre os NBRs pré e pós fogo, e dVV e dVH às diferenças pré e pós-fogo de σ_{VV}^0 e σ_{VH}^0 , respectivamente.



Fonte: Elaborado pela autora.

Para a análise, foram selecionados dados ópticos e SAR correspondentes a períodos anteriores e posteriores às queimadas na área de estudo. As imagens ópticas foram adquiridas em 20 de junho de 2020 (pré-fogo) e 22 de novembro de 2020 (pós-fogo) em Nível 2A (BOA), já corrigido atmosféricamente. O pré-processamento incluiu a reamostragem para 20 metros de resolução espacial e o recorte conforme os limites da área de estudo.

Quanto aos dados SAR, as aquisições foram realizadas em 15 de junho de 2020 (pré-fogo) e 24 de novembro de 2020 (pós-fogo), no formato SLC e modo de aquisição IW. Para a extração dos coeficientes de retroespalhamento σ_{VV}^0 e σ_{VH}^0 , foram aplicadas as etapas de pré-processamento ilustradas na Figura 36, específicas para produtos SLC.

Na etapa de *split*, foi selecionada a subfaixa IW2 e os *bursts* de 5 a 8, suficientes para cobrir a área de estudo. No procedimento de *multilooking*, foram adotados 4×1 looks (distância $\times$ azimuth). Para a etapa de filtragem, foi aplicado o filtro Refined Lee, com janela de 3×3 pixels. Ao final, as imagens também foram reamostradas para 20 metros de resolução espacial, garantindo a consistência com os dados ópticos do Sentinel-2.

A partir dos dados ópticos, foi calculado o índice NBR para as imagens pré e pós-fogo, assim como a diferença entre elas, o índice $dNBR$ (Equação 8). Para os dados SAR, foram extraídos os coeficientes σ_{VV}^0 e σ_{VH}^0 nas datas pré e pós-fogo, e então calculadas as diferenças entre as duas datas, resultando nas imagens diferença dVV e dVH , respectivamente.

Para a detecção das áreas queimadas, as três imagens diferença ($dNBR$, dVV e dVH) foram classificadas individualmente utilizando o algoritmo baseado em ML RF, considerando duas classes de saída: áreas queimadas e áreas não queimadas.

A coleta das amostras utilizadas nas classificações foi realizada com base na interpretação visual das imagens ópticas em composição colorida verdadeira (R4G3B2/Sentinel-2), referentes aos períodos pré e pós-incêndio (20 de junho e 22 de novembro de 2020, respectivamente), além da análise do índice dNBR gerado.

Esse processo foi complementado por informações sobre focos de calor obtidas no programa Queimadas, do INPE (<https://queimadas.dgi.inpe.br/queimadas/bdqueimadas>), com ênfase nas áreas mais severamente afetadas pelo fogo. Para a etapa de classificação, os dados amostrais foram divididos em 70% para treinamento e 30% para validação do modelo.


Os modelos RF gerados e utilizados nas classificações foram avaliados por meio das métricas de desempenho *Recall*, *Precision*, *F-Score* e Acurácia. Adicionalmente, os resultados das classificações dos produtos SAR (dVV e dVH) foram comparados, de forma individual, à classificação da imagem dNBR, permitindo a análise das proporções de coincidência e divergência entre os diferentes produtos. Mais detalhes sobre a metodologia adotada, o pré-processamento das imagens e a parametrização do algoritmo RF podem ser consultados em Marra et al. (2024).

4.4.3 Detecção de áreas queimadas em imagens SAR por meio de segmentação semântica

A utilização da segmentação semântica na detecção de áreas queimadas em imagens SAR foi abordada em um experimento aplicado em parte do PEEA, no Pantanal Mato-Grossense, afetada por eventos de fogo extremo ocorridos em 2020. A rede U-Net foi escolhida por sua arquitetura eficiente, baseada em conexões de atalho (*skip connections*), que possibilitam a integração de informações semânticas e espaciais em múltiplas escalas, preservando detalhes finos necessários para a segmentação precisa.

Os resultados obtidos foram divulgados em artigo intitulado “*Burnt areas semantic segmentation from Sentinel data using the U-Net network trained with semi-automated annotations*” publicado no *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* (<https://doi.org/10.5194/isprs-archives-XLVIII-1-W2-2023-1459-2023>) e apresentado no evento do *International Society for Photogrammetry and Remote Sensing* (ISPRS), que ocorreu em setembro de 2023 no Cairo, Egito. A Figura 38 apresenta o fluxograma geral da metodologia desenvolvida para o experimento.


Figura 38 - Fluxograma geral da metodologia aplicada no experimento, em que PA se refere ao índice polarimétrico *Polarization Averaging*, NBR e NDWI aos índices espectrais ópticos *Normalized Burn Ratio* e *Normalized Difference Water Index*, respectivamente; e dNBR à diferença entre os NBRs pré e pós-fogo. Focos de calor INPE correspondem a pontos detectados via satélite que indicam áreas com altas temperaturas, geralmente associadas a queimadas.



Fonte: Elaborado pela autora.

Para o desenvolvimento do estudo, foi utilizada uma área abrangendo parte do PEEA com o objetivo de otimizar o processamento dos dados, uma vez que a geração de um mosaico de imagens para cobrir toda a extensão do parque exigiria maior capacidade computacional e aumentaria significativamente a complexidade das etapas de pré-processamento. A Figura 39 ilustra a área com parte do PEEA utilizada na detecção de áreas queimadas, apresentada por uma imagem Sentinel-2 em composição colorida verdadeira, adquirida em 20 de julho de 2020. O limite de parte do parque está destacado em amarelo.

Figura 39 – Área incluindo parte do PEEA utilizada na detecção de áreas queimadas com aplicação da rede de segmentação semântica U-Net, sobre imagem de fundo Sentinel-2 (composição colorida verdadeira), adquirida em 20 de julho de 2020, com o limite do parque destacado em amarelo.



Fonte: Adaptado de Marra *et al.* (2023)

Foram selecionadas imagens ópticas MSI/Sentinel-2 pré e pós-fogo, em refletância de superfície (Nível 2A), adquiridas em 20 de julho e 22 de novembro de 2020, respectivamente. As imagens foram reamostradas para 20 metros de resolução espacial e os índices ópticos NBR e NDWI foram calculados. Posteriormente, foi gerada a diferença entre os valores de NBR pré e pós-fogo (dNBR), utilizada para avaliar a extensão e a severidade das áreas queimadas.

Os dados SAR/Sentinel-1 foram obtidos apenas para o período pós-fogo, correspondendo a uma cena tomada em 24 de novembro de 2020, no formato GRD. As imagens foram processadas para obtenção dos coeficientes de retroespalhamento σ_{VV}^0 e σ_{VH}^0 , seguindo as etapas de pré-processamento descritas na Figura 36, específicas para produtos GRD. Após o pré-processamento, foi calculado o índice polarimétrico PA, conforme apresentado na Tabela 3.

O dNBR, calculado a partir das imagens ópticas, foi utilizado como base para a geração da anotação empregada no treinamento da rede U-Net. Para isso, foi aplicado um limiar sobre o dNBR, selecionando apenas as áreas severamente queimadas definidas no intervalo de +0,66 a +1,30, conforme proposto por Key e Benson (2006) e validado por inspeção visual. Esse critério teve como objetivo isolar as áreas mais afetadas pelo fogo,

excluindo zonas de baixa e média severidade, permitindo à rede U-Net aprender com exemplos mais representativos e minimizar a ocorrência de falsos positivos.

Além disso, uma máscara foi aplicada para a remoção de corpos d'água que apresentavam valores de dNBR semelhantes aos das áreas queimadas. Essa máscara foi gerada utilizando o índice NDWI, adotando o limiar $NDWI \geq 0$, conforme definido por McFeeters (1996). Por fim, foi empregado o filtro *Sieve* para eliminar áreas menores que 300 pixels, resultando em uma imagem final binária, com a representação apenas das classes de área queimada e área não queimada.

Paralelamente, foram adquiridos dados de focos de calor na área de estudo por meio do banco de dados do programa Queimadas do INPE. Os focos considerados se referem ao período de queimadas intensas adotado neste estudo, compreendido entre 20 de junho e 22 de novembro de 2020. Elaborou-se um mapa de densidade de *Kernel* com esses focos, que permitiu identificar espacialmente as regiões mais afetadas pelo fogo. Esse mapa foi posteriormente comparado, de forma visual, à anotação gerada com base nos dados ópticos do Sentinel-2, contribuindo para a validação da delimitação das áreas queimadas.

Para a aplicação da rede U-Net (descrita na subseção 3.4), dois conjuntos de dados pós-fogo foram testados: um combinando dados ópticos e SAR (incluindo o índice espectral óptico NBR e os coeficientes de retroespalhamento σ_{VV}^0 e σ_{VH}^0) e outro contendo apenas dados SAR (σ_{VV}^0 e σ_{VH}^0 e o índice polarimétrico PA). Ambos foram empilhados correspondendo exatamente à área da anotação gerada.

A implementação da rede U-Net foi realizada em linguagem Python. Os dois conjuntos de dados e a anotação gerada foram subdivididos em patches de 256×256 pixels utilizando a biblioteca Patchify. A arquitetura foi implementada por meio da biblioteca segmentation-models e os dados foram divididos aleatoriamente em 75% para treinamento e 25% para validação. Os hiperparâmetros adotados incluíram o *Encoder* ResNet-34 e o otimizador Adam, e o número de épocas foi definido como 100.

Adicionalmente, foi aplicada a técnica de *Data Augmentation* com o objetivo de aumentar artificialmente o tamanho do conjunto de dados. Para isso, foram definidos os seguintes parâmetros de transformação: rotação de 90° , deslocamento horizontal (*width shift*), deslocamento vertical (*height shift*), fator de zoom de 0,3, inversão horizontal (*horizontal flip*) e inversão vertical (*vertical flip*) definidos como *True* e modo de preenchimento como *Reflect*.

Após o processamento da rede U-Net, foram geradas figuras representando a distribuição espacial das áreas queimadas referentes à predição dos dois conjuntos de dados: Óptico/SAR e somente SAR. Para avaliar os resultados, foi calculada a métrica *Intersection over Union* (IoU) entre as áreas queimadas detectadas pela rede nos dois conjuntos e a anotação de referência.

A métrica IoU é amplamente utilizada para avaliar a precisão de detecção de objetos em visão computacional. Ela mede a sobreposição entre o objeto predito pelo modelo e o objeto real (anotação gerada, no caso deste estudo). Em outros termos, o IoU corresponde à razão entre a área de interseção e a área de união dos dois conjuntos. De acordo com Everingham *et al.* (2010), uma predição é considerada adequada quando o IoU é maior ou igual a 0,5. A definição matemática da métrica é apresentada na Equação 9:


$$IoU = \frac{\text{Área da intersecção}}{\text{Área da União}} \quad \text{Equação 9}$$

Além do cálculo do IoU, também foram estimadas as áreas classificadas como queimadas para ambas as predições, bem como para a anotação de referência, expressas em hectares. O tempo de processamento de cada conjunto de dados também foi registrado e comparado. Por fim, o treinamento da rede forneceu as curvas de perda (*loss*) e acurácia (*accuracy*), tanto para os dados de treinamento quanto de validação.

4.4.4 Mapeamento de áreas queimadas por tipo de cobertura da terra, a partir de imagens SAR de 2020

Foi conduzido um estudo com o objetivo de avaliar o desempenho de diferentes classificadores baseados em ML integrados ao ambiente do GEE, na detecção e mapeamento de áreas queimadas. Além da utilização de modelos menos complexos que a U-Net, possibilitando o mapeamento de toda a extensão de PEEA, a análise contemplou os diversos tipos de vegetação natural e de uso e cobertura da terra na UC, utilizando exclusivamente imagens SAR. Todos os processamentos aplicados aos dados SAR foram implementados na plataforma GEE. O fluxograma geral da metodologia adotada nesta abordagem é mostrado na Figura 40.

Figura 40 - Fluxograma geral da metodologia aplicada neste experimento.



Fonte: Elaborado pela autora.


Conforme apresentado no fluxograma geral desta abordagem (Figura 40), a primeira etapa consistiu na definição de imagens SAR tomadas antes e após o período de queimadas intensas ocorrido em 2020, correspondentes aos dias 27 de julho e 24 de novembro, respectivamente. As imagens provenientes da missão Sentinel-1 foram acessadas por meio da coleção “COPERNICUS/S1_GRD” na plataforma GEE, no formato GRD, já processadas com as correções necessárias e valores de retroespalhamento expressos em decibéis (dB).

Com base nas imagens SAR, foram calculados os índices polarimétricos CR, RVI, DPSVI, NRPB, DPDD e PA (Tabela 3), tanto para as imagens pré quanto para as pós-fogo. Em seguida, foram obtidas as imagens de diferença entre os períodos pré-fogo e pós-fogo (subtração pré-fogo – pós-fogo) dos coeficientes de retroespalhamento (dVV e dVH), bem como dos índices polarimétricos (dVV, dVH, dCR, dRVI, dDPSVI, dNRPB, dDPDD e dPA).

A partir dos dados de uso e cobertura da terra do MapBiomias Coleção Beta, foram extraídas as feições correspondentes aos corpos d’água, permitindo a geração de uma máscara destinada à remoção dessas áreas nas imagens diferença na extensão do PEEA, com o objetivo de minimizar a interferência de corpos d’água durante o processo de classificação. A Figura 41(a) apresenta os corpos d’água extraídos dos tipos de uso e cobertura do solo no PEEA, do Projeto Mapbiomas – Coleção Beta, referente ao ano de

2020, enquanto a Figura 41(b) exibe a composição final dos tipos de uso e cobertura do solo após a aplicação da máscara, evidenciando o parque com os corpos d'água removidos.

Figura 41 - Máscara d'água do PEEA gerada para processamento dos dados, em que a) mostra a extração de corpos d'água dos tipos de uso e cobertura do solo do Projeto Mapbiomas – Coleção Beta, referente ao ano de 2020, e b) os tipos de uso e cobertura do solo após a aplicação da máscara.




Fonte: Elaborado pela autora com dados do Projeto MapBiomas – Coleção Beta (2025).

No processo de classificação, foram testados quatro algoritmos baseados em ML: RF, SVM, CART e KNN. A escolha desses algoritmos se deve à sua reconhecida eficiência computacional, facilidade de implementação e desempenho adequado em diversas aplicações, além da disponibilidade na plataforma GEE, que contribui para a automação e agilidade no processamento. Essas características os tornam competitivos em tarefas de aprendizado supervisionado, especialmente por não exigirem ajustes extensivos de hiperparâmetros, diferentemente dos modelos de DL, que geralmente demandam maior complexidade computacional e tempo de treinamento.

As classificações consideraram duas classes de saída: áreas queimadas e não queimadas. Para cada classe, foram coletadas aproximadamente 2.000 km² em amostras, distribuídas entre os diferentes tipos de uso e cobertura do solo presentes na área de estudo, com exceção de corpos d'água. A coleta das amostras foi realizada por meio de

interpretação visual de imagens ópticas Sentinel-2 em composição colorida verdadeira (4R3G2B), adquiridas antes e após o período de queimadas, correspondendo aos dias 20 de julho (pré-fogo) e 22 de novembro (pós-fogo) de 2020 (Figura 30). A seleção dessas imagens considerou a maior proximidade possível das datas das aquisições SAR, bem como a ausência de cobertura de nuvens. As classificações foram executadas com os parâmetros padrões (*default*) de cada algoritmo. A distribuição espacial das amostras de áreas queimadas e não queimadas adquiridas no PEEA, pode ser observada na Figura 42.

Figura 42 - Distribuição espacial das amostras coletadas na área de estudo, em que os polígonos em vermelho se referem às áreas queimadas e em preto, às áreas não queimadas. O uso e cobertura do solo corresponde ao mapeamento do MapBiomias, Coleção Beta (ano de 2020).



Fonte: Elaborado pela autora com dados do Projeto MapBiomias – Coleção Beta (2025).

As amostras coletadas (Figura 42) foram divididas aleatoriamente, sendo 80% destinadas ao treinamento dos algoritmos e 20% utilizadas para a validação dos modelos. Os modelos foram avaliados com base nos dados separados do treinamento (20%), por meio de métricas clássicas de acurácia: AG, coeficiente Kappa e *F-Score*, calculados a partir da Matriz de Confusão. Especificamente para o classificador RF, foi extraído e analisado o *ranking* de importância dos atributos utilizados na classificação, contribuindo

para a compreensão dos atributos de maior relevância na discriminação entre áreas queimadas e não queimadas.

Os modelos resultantes do uso de cada algoritmo foram aplicados às imagens SAR diferença utilizadas como base para o treinamento. Como resultado das classificações, foram obtidas imagens indicando áreas queimadas e não queimadas em toda a extensão da área de estudo. Após o processo de classificação, foi utilizado um filtro para remover agrupamentos com menos de 30 pixels, visando eliminar ruídos e pequenas detecções isoladas. Posteriormente, para cada classificação individual, foi calculado o índice de similaridade IoU entre as áreas queimadas detectadas e aquelas mapeadas pelo Projeto MapBiomias – Monitor do Fogo (Figura 34) considerando os meses de abrangência das imagens SAR (agosto, setembro, outubro e novembro de 2020).

Devido à presença de corpos d'água identificados como áreas queimadas no produto do MapBiomias – Monitor do Fogo, foi aplicada a máscara d'água gerada (Figura 41) às áreas delimitadas pelo projeto, previamente ao cálculo do IoU, a fim de remover essas feições. O valor do IoU também foi utilizado para identificar o algoritmo de classificação mais eficiente na detecção de áreas queimadas, indicando aquele de maior correspondência com os dados de referência.

Por fim, foram elaborados dois mapas temáticos representando as áreas queimadas identificadas pelo modelo de ML de melhor desempenho. O primeiro mapa apresentando a área total identificada como queimada pelo classificador, e o segundo, as áreas identificadas como queimadas conforme os tipos de uso e cobertura do solo. Essa última representação foi obtida por meio da interseção espacial do resultado da classificação com o produto da Coleção Beta do MapBiomias, referente ao ano de 2020.


4.4.5 Construção e análise de séries temporais de atributos polarimétricos SAR

Conforme explicitado anteriormente, as séries temporais de atributos ópticos e SAR foram essenciais para analisar a dinâmica temporal e os impactos de queimadas na área de estudo, a UC PEEA. Para o desenvolvimento do estudo, foram selecionados atributos polarimétricos SAR para a construção e análise de séries temporais, considerando os diferentes tipos de uso e cobertura da terra no parque.

Complementarmente, foram elaboradas séries temporais dos índices espectrais tradicionais NDVI e NBR, obtidos a partir de imagens ópticas do Sentinel-2, além da incorporação de informações meteorológicas de precipitação e temperatura. A integração

desses dados visou aprimorar a compreensão dos padrões sazonais e das alterações na paisagem associadas à ocorrência de queimadas e à regeneração da vegetação ao longo do tempo. A metodologia geral aplicada nesta etapa, é apresentada no fluxograma da Figura 43.

Figura 43 - Metodologia geral aplicada na geração das series temporais de dados SAR e ópticos. FF se refere à Formação Florestal, FS à Formação Savânica, CAAP à Campo Alagado e Área Pantanosa, FC à Formação Campestre e P à Pastagem.



Fonte: Elaborado pela autora.

Como mostra a Figura 43, inicialmente foram definidos atributos SAR para a construção de séries temporais individuais, considerando os diferentes tipos de vegetação e classes de uso e cobertura do solo da área de estudo, com o objetivo de caracterizar o comportamento dessas áreas quando submetidas ao fogo. Os atributos analisados foram os coeficientes de retroespalhamento σ_{VV}^0 e σ_{VH}^0 , além dos índices polarimétricos CR, RVI, DPSVI, NRPB, DPDD e PA.

A seleção dos atributos considerou dois procedimentos: o *ranking* de importância gerado pelo algoritmo RF e a análise da separabilidade entre as classes de áreas queimadas e não queimadas. Ambos os procedimentos utilizaram as amostras dessas classes coletadas conforme a abordagem apresentada na Seção 4.4.4 e extraídas da

imagem SAR adquirida em 24 de novembro de 2020, após o evento de fogo. No primeiro procedimento, as amostras foram aplicadas ao RF para obter o *ranking* de importância dos atributos; no segundo, as médias dos valores das amostras foram utilizadas para calcular a separabilidade individual de cada atributo.

Com a definição dos atributos SAR a serem utilizados na construção das séries temporais, foi delimitada a área a ser monitorada ao longo do tempo. Essa área corresponde à intersecção entre a classificação de áreas queimadas no PEEA referente ao algoritmo de melhor desempenho (apresentada na subseção 4.4.4) e os dados do MapBiomass – Monitor do Fogo referente ao ano de 2020. As áreas resultantes dessa intersecção foram segmentadas segundo os diferentes tipos de uso e cobertura do solo, por meio de uma nova intersecção com os dados do MapBiomass – Coleção Beta, de 2020.

Após a delimitação das áreas segundo os tipos de uso e cobertura do solo e a definição dos atributos SAR, foram geradas séries temporais mensais abrangendo o intervalo de janeiro de 2019 a dezembro de 2024, período comum de disponibilidade de dados SAR e ópticos na plataforma GEE, para toda a extensão da área de estudo. As imagens provenientes das missões Sentinel-1 e Sentinel-2 foram acessadas por meio das coleções “COPERNICUS/S1_GRD” e “COPERNICUS/S2_SR_HARMONIZED”, respectivamente, cobrindo o período de análise. Para as imagens ópticas, foi atribuído um limiar de no máximo 30% de cobertura de nuvens. Ambas as coleções disponibilizam as imagens já processadas com as correções necessárias.

No caso do sensor Sentinel-1, a série temporal contou com 177 cenas provenientes exclusivamente do satélite S1A, adquiridas sistematicamente com frequência de revisita de 12 dias, resultando em duas ou três coletas mensais. Para o sensor óptico Sentinel-2, foram obtidas 229 imagens dos satélites S2A e S2B, com disponibilidade variando de uma a cinco aquisições por mês. O Quadro 4 e Quadro 5 apresentam as datas de aquisição das imagens SAR e ópticas acessadas, respectivamente.

Quadro 4 - Datas de aquisição das imagens SAR do sensor Sentinel-1A empregadas na composição das séries temporais mensais. As cenas foram adquiridas entre janeiro de 2019 e dezembro de 2024. A alternância entre células cinza agrupa visualmente a divisão das aquisições por mês ao longo das séries temporais.

Sentinel-1							
1	10/01/2019	51	13/09/2020	101	18/05/2022	151	01/02/2024
2	22/01/2019	52	25/09/2020	102	30/05/2022	152	13/02/2024
3	03/02/2019	53	07/10/2020	103	11/06/2022	153	25/02/2024
4	27/02/2019	54	19/10/2020	104	23/06/2022	154	08/03/2024

5	11/03/2019	55	31/10/2020	105	05/07/2022	155	20/03/2024
6	23/03/2019	56	12/11/2020	106	17/07/2022	156	01/04/2024
7	04/04/2019	57	24/11/2020	107	29/07/2022	157	13/04/2024
8	16/04/2019	58	06/12/2020	108	10/08/2022	158	25/04/2024
9	28/04/2019	59	18/12/2020	109	22/08/2022	159	07/05/2024
10	10/05/2019	60	30/12/2020	110	03/09/2022	160	19/05/2024
11	22/05/2019	61	11/01/2021	111	15/09/2022	161	31/05/2024
12	03/06/2019	62	23/01/2021	112	27/09/2022	162	12/06/2024
13	15/06/2019	63	04/02/2021	113	09/10/2022	163	06/07/2024
14	27/06/2019	64	16/02/2021	114	21/10/2022	164	18/07/2024
15	09/07/2019	65	28/02/2021	115	02/11/2022	165	30/07/2024
16	21/07/2019	66	12/03/2021	116	14/11/2022	166	11/08/2024
17	02/08/2019	67	24/03/2021	117	26/11/2022	167	23/08/2024
18	14/08/2019	68	05/04/2021	118	08/12/2022	168	04/09/2024
19	26/08/2019	69	17/04/2021	119	20/12/2022	169	16/09/2024
20	07/09/2019	70	29/04/2021	120	01/01/2023	170	28/09/2024
21	19/09/2019	71	11/05/2021	121	13/01/2023	171	10/10/2024
22	01/10/2019	72	23/05/2021	122	25/01/2023	172	22/10/2024
23	13/10/2019	73	04/06/2021	123	06/02/2023	173	03/11/2024
24	25/10/2019	74	16/06/2021	124	18/02/2023	174	15/11/2024
25	06/11/2019	75	28/06/2021	125	02/03/2023	175	27/11/2024
26	18/11/2019	76	10/07/2021	126	14/03/2023	176	09/12/2024
27	30/11/2019	77	22/07/2021	127	26/03/2023	177	21/12/2024
28	12/12/2019	78	03/08/2021	128	07/04/2023		
29	24/12/2019	79	15/08/2021	129	19/04/2023		
30	05/01/2020	80	27/08/2021	130	01/05/2023		
31	17/01/2020	81	08/09/2021	131	13/05/2023		
32	29/01/2020	82	20/09/2021	132	25/05/2023		
33	10/02/2020	83	02/10/2021	133	18/06/2023		
34	22/02/2020	84	14/10/2021	134	30/06/2023		
35	05/03/2020	85	26/10/2021	135	24/07/2023		
36	17/03/2020	86	07/11/2021	136	05/08/2023		
37	29/03/2020	87	19/11/2021	137	17/08/2023		
38	10/04/2020	88	01/12/2021	138	29/08/2023		
39	22/04/2020	89	13/12/2021	139	10/09/2023		
40	04/05/2020	90	06/01/2022	140	22/09/2023		
41	16/05/2020	91	18/01/2022	141	04/10/2023		
42	28/05/2020	92	30/01/2022	142	16/10/2023		
43	09/06/2020	93	11/02/2022	143	28/10/2023		
44	21/06/2020	94	23/02/2022	144	09/11/2023		
45	03/07/2020	95	07/03/2022	145	21/11/2023		
46	15/07/2020	96	19/03/2022	146	03/12/2023		
47	27/07/2020	97	31/03/2022	147	15/12/2023		
48	08/08/2020	98	12/04/2022	148	27/12/2023		
49	20/08/2020	99	24/04/2022	149	08/01/2024		
50	01/09/2020	100	06/05/2022	150	20/01/2024		

Quadro 5 - Datas de aquisição das imagens do sensor Sentinel-2 (satélites S2A e S2B) empregadas na composição das séries temporais mensais. As cenas foram adquiridas entre janeiro de 2019 e dezembro de 2024 e filtradas para cobertura de nuvens máxima de 30%. A alternância entre células cinza agrupa visualmente a divisão das aquisições por mês ao longo das séries temporais. As células destacadas em laranja indicam meses com falhas ou ausência de imagens ópticas devido à elevada cobertura de nuvens.

Sentinel-2									
1	02/01/2019	51	21/05/2020	101	15/07/2021	151	29/08/2022	199	05/04/2024
2	01/02/2019	52	26/05/2020	102	20/07/2021	152	03/09/2022	200	20/04/2024
3	06/02/2019	53	31/05/2020	103	25/07/2021	153	03/09/2022	201	25/04/2024
4	08/03/2019	54	10/06/2020	104	30/07/2021	154	08/09/2022	202	30/04/2024
5	13/03/2019	55	20/06/2020	105	09/08/2021	155	13/09/2022	203	05/05/2024
6	23/03/2019	56	25/06/2020	106	14/08/2021	156	18/09/2022	204	10/05/2024
7	02/04/2019	57	30/06/2020	107	19/08/2021	157	28/10/2022	205	30/05/2024
8	07/05/2019	58	05/07/2020	108	24/08/2021	158	02/11/2022	206	04/06/2024
9	17/05/2019	59	10/07/2020	109	03/09/2021	159	17/11/2022	207	09/06/2024
10	27/05/2019	60	15/07/2020	110	08/09/2021	160	27/11/2022	208	14/06/2024
11	01/06/2019	61	20/07/2020	111	13/09/2021	dez/2022		209	19/06/2024
12	06/06/2019	62	25/07/2020	112	18/09/2021	161	16/01/2023	210	24/06/2024
13	11/06/2019	63	30/07/2020	113	28/09/2021	fev/2023		211	29/06/2024
14	16/06/2019	64	09/08/2020	114	03/10/2021	162	02/03/2023	212	14/07/2024
15	21/06/2019	65	14/08/2020	115	08/10/2021	163	27/03/2023	213	19/07/2024
16	01/07/2019	66	19/08/2020	116	13/10/2021	164	21/04/2023	214	24/07/2024
17	06/07/2019	67	24/08/2020	117	23/10/2021	165	26/04/2023	215	29/07/2024
18	11/07/2019	68	29/08/2020	118	02/11/2021	166	16/05/2023	216	03/08/2024
19	16/07/2019	69	03/09/2020	119	22/11/2021	167	26/05/2023	217	18/08/2024
20	26/07/2019	70	08/09/2020	120	02/12/2021	168	05/06/2023	218	23/08/2024
21	31/07/2019	71	13/09/2020	121	07/12/2021	169	10/06/2023	219	28/08/2024
22	05/08/2019	72	28/09/2020	122	27/12/2021	170	20/06/2023	220	02/09/2024
23	10/08/2019	73	03/10/2020	123	01/01/2022	171	25/06/2023	221	07/09/2024
24	15/08/2019	74	08/10/2020	124	11/01/2022	172	30/06/2023	222	12/09/2024
25	20/08/2019	75	13/10/2020	125	21/01/2022	173	05/07/2023	223	17/09/2024
26	25/08/2019	76	18/10/2020	126	15/02/2022	174	10/07/2023	224	22/09/2024
27	30/08/2019	77	02/11/2020	127	25/02/2022	175	15/07/2023	225	02/10/2024
28	04/09/2019	78	22/11/2020	128	07/03/2022	176	20/07/2023	226	12/10/2024
29	09/09/2019	79	02/12/2020	129	22/03/2022	177	25/07/2023	227	22/10/2024
30	14/09/2019	80	12/12/2020	130	06/04/2022	178	30/07/2023	nov/2024	
31	19/09/2019	81	26/01/2021	131	11/04/2022	179	04/08/2023	228	06/12/2024
32	24/09/2019	82	10/02/2021	132	16/04/2022	180	09/08/2023	229	31/12/2024
33	24/10/2019	83	20/02/2021	133	21/04/2022	181	24/08/2023		
34	18/11/2019	84	25/02/2021	134	26/04/2022	182	29/08/2023		
35	23/11/2019	85	22/03/2021	135	01/05/2022	183	03/09/2023		
36	08/12/2019	86	27/03/2021	136	06/05/2022	184	08/09/2023		
37	28/12/2019	87	01/04/2021	137	11/05/2022	185	23/09/2023		
38	27/01/2020	88	16/04/2021	138	21/05/2022	186	03/10/2023		
39	16/02/2020	89	21/04/2021	139	05/06/2022	187	18/10/2023		
40	02/03/2020	90	01/05/2021	140	15/06/2022	188	02/11/2023		

41	07/03/2020	91	11/05/2021	141	20/06/2022	189	12/11/2023
42	12/03/2020	92	16/05/2021	142	25/06/2022	190	07/12/2023
43	17/03/2020	93	21/05/2021	143	30/06/2022	191	27/12/2023
44	01/04/2020	94	26/05/2021	144	10/07/2022	192	06/01/2024
45	11/04/2020	95	15/06/2021	145	15/07/2022	193	16/01/2024
46	16/04/2020	96	20/06/2021	146	20/07/2022	194	26/01/2024
47	21/04/2020	97	25/06/2021	147	25/07/2022	195	31/01/2024
48	26/04/2020	98	30/06/2021	148	30/07/2022	196	25/02/2024
49	01/05/2020	99	05/07/2021	149	14/08/2022	197	16/03/2024
50	11/05/2020	100	10/07/2021	150	24/08/2022	198	21/03/2024

Apesar da maior capacidade de revisita proporcionada pela operação conjunta dos satélites ópticos S2A e S2B, foram verificadas falhas nas séries temporais em dezembro de 2022, fevereiro de 2023 e novembro de 2024, conforme destacado na cor amarela no Quadro 5, devido à possível elevada cobertura de nuvens, o que resultou na ausência de coletas adequadas para esses meses.

A partir desses conjuntos de dados, foram calculadas as médias mensais dos valores dos pixels pertencentes a cada classe de uso e cobertura do solo, para cada atributo selecionado. Também foram obtidos os valores de desvio-padrão, calculados para cada imagem individualmente, dentro de cada classe, e posteriormente sua média mensal. Desse modo, para cada um dos atributos SAR selecionados, foi construída uma série temporal contendo os valores de média e desvio padrão de cada classe de uso e cobertura do solo do PEEA, incluindo Formação Florestal (FF), Formação Savânica (FS), Formação Campestre (FC), Campo Alagado e Área Pantanosa (CAAP) e Pastagem (P). Além dos atributos SAR selecionados, séries temporais também foram produzidas para os índices espectrais ópticos NDVI e NBR.

Para complementar a análise temporal, foram incorporados nas séries temporais de atributos ópticos e SAR, dados históricos das variáveis meteorológicas precipitação e temperatura, abrangendo o mesmo período de aquisição das imagens (janeiro de 2019 a dezembro de 2024). No momento da coleta, porém, os dados de precipitação estavam disponíveis apenas até setembro de 2024.

Os dados de precipitação foram fornecidos em médias mensais pela estação pluviométrica Ilha Camargo, sob responsabilidade da ANA, por meio do Portal HidroWeb. Os dados de temperatura, também em médias mensais, se referem à variável LST_day (temperatura da superfície durante o dia), extraída dos produtos MODIS,

acessados via GEE (coleção “MODIS/061/MYD21C3”), conforme detalhado nas subseções 4.2.4.1 e 4.2.4.2, respectivamente.

Os dados meteorológicos foram analisados em conjunto com as variáveis extraídas das imagens SAR e ópticas, com o objetivo de identificar possíveis relações entre fatores climáticos e as alterações nas séries temporais associadas à ocorrência de queimadas. Essa abordagem contribuiu para uma compreensão mais aprofundada da influência da precipitação e da temperatura na dinâmica do fogo e nas transformações ocorridas na área afetada, ao longo do tempo.

Adicionalmente, visando aprofundar a compreensão da relação entre os atributos SAR e os índices espectrais derivados das imagens ópticas, foi realizada uma análise de correlação entre o NBR e o NDVI e os atributos polarimétricos selecionados, considerando separadamente cada classe de uso e cobertura do solo do PEEA. Foi utilizado o coeficiente de correlação de Pearson (PEARSON, 1895), que varia de -1 a +1 e indica a intensidade da relação linear entre duas variáveis. Valores próximos de +1 apontam forte correlação positiva, valores próximos de 0 sugerem fraca ou nenhuma relação linear e valores próximos de -1 indicam forte correlação negativa.

O cálculo do coeficiente de correlação de Pearson foi realizado em ambiente Python, com a função `pearsonr()` (biblioteca SciPy), utilizando as médias mensais previamente obtidas para cada classe. Essa etapa, permitiu identificar o grau de similaridade temporal entre os índices espectrais e os parâmetros SAR.

Por fim, foi realizada a análise das séries temporais por meio da aplicação do algoritmo BFAST, implementado na linguagem R. Esse procedimento permitiu a identificação de mudanças estruturais significativas nas séries temporais, ao decompor o espectro temporal em componentes de tendência e sazonalidade, possibilitando a detecção precisa de rupturas associadas à ocorrência de queimadas.

O valor do parâmetro h do BFAST, que determina o tamanho mínimo dos segmentos entre pontos de quebra, foi definido considerando a resolução temporal da série e a escala temporal das mudanças relevantes. Para uma série mensal de 6 anos (72 observações), a adoção de $h = 12/72$ estabelece um limite mínimo de 12 meses por segmento, alinhando-se com a necessidade de detectar mudanças estruturais que perdurem ao menos um ciclo anual completo. Essa escolha evita que variações pontuais ou ruídos sazonais sejam interpretados como quebras reais. Estudos como Watts e Laffan (2013) destacam que o valor de h influencia na sensibilidade e precisão da detecção de mudanças, recomendando que a configuração seja ajustada ao ritmo temporal dos

processos estudados, o que reforça a adequação do valor adotado para séries com dados mensais com cobertura de vários anos.


5. RESULTADOS

5.1 Potencial dos atributos SAR/Sentinel-1 no mapeamento de áreas queimadas do PEEA

Nesta seção serão apresentados os resultados obtidos no experimento, cuja metodologia foi descrita na seção 4.4.2. O objetivo do experimento foi avaliar o potencial de imagens SAR no mapeamento de áreas queimadas na área de estudo. Para isso, foram classificadas as imagens diferença SAR dVH e dVV e a imagem dNBR, derivada de dados ópticos, utilizando o algoritmo RF. Em seguida, os resultados das classificações SAR foram comparados, individualmente, com a classificação da imagem dNBR.

Para representar a distribuição espacial das áreas queimadas e não queimadas resultante das classificações RF baseadas nas imagens diferença dNBR, dVH e dVV, foram elaborados mapas temáticos, apresentados na Figura 44(a), (b) e (c), respectivamente, onde a cor vermelha indica as áreas queimadas, enquanto a cor verde representa as áreas não queimadas.

Figura 44 - Classificação das diferenças a) dNBR, b) dVH e c) dVV, onde as áreas queimadas estão representadas em vermelho e as não queimadas, em verde.



Fonte: Marra *et al.* (2024)

Conforme apresentado na Figura 44, o dNBR indicou que 42% da área total foi classificada como queimada, enquanto as diferenças de retroespalhamento SAR dVH e dVV mostraram uma proporção maior, de 55% e 52%, respectivamente. Quanto ao desempenho das classificações, a Tabela 5 apresenta as métricas Kappa, AG, *Recall*, e

Precision e *F-Score*, obtidas da aplicação dos modelos RF nas diferenças dNBR, dVH e dVV, com base nos dados de validação.

Tabela 5 - Desempenho dos modelos de RF na detecção de áreas queimadas nas imagens dNBR, dVH e dVV, referente aos 30% de dados de validação.


	dNBR	dVH	dVV
Kappa	1,000	0,920	0,880
AG	1,000	0,960	0,940
Recall	1,000	0,972	0,942
Precision	0,998	0,946	0,928
F-Score	0,999	0,959	0,935

Fonte: Marra *et al.* (2024)

Os resultados estimados com base em 30% das anotações coletadas indicados na Tabela 5, mostram que o dNBR atingiu valores máximos para o coeficiente Kappa, AG e *Recall* (1,00) e apresentou valores acima de 0,99 para as demais métricas. Todas as métricas calculadas para o dVH indicaram resultados sutilmente melhores em relação à diferença do dVV, sendo as maiores diferenças comparando o coeficiente Kappa (0,04) e o *Recall* (0,03). A diferença máxima entre os resultados do dNBR e do dVH, que obteve o melhor desempenho entre os dados SAR, foi de 0,08 para o coeficiente Kappa.

A comparação entre as classificações geradas a partir das diferenças SAR dVH e dVV, com a classificação do dNBR, permitiu analisar a coincidência entre as áreas queimadas individualmente, para cada diferença SAR. Os resultados são mostrados na Figura 45.

Figura 45 - Mapas temáticos resultantes da comparação individual entre a classificação de a) dNBR com dVH e b) dNBR com dVV. A cor azul representa áreas não queimadas em dVH e dVV e queimadas em dNBR; a cor magenta, áreas queimadas em dVH e dVV e não queimadas em dNBR; e a branca, áreas coincidentes.



Comparando as classificações dVH e dVV individualmente com a classificação dNBR, os resultados mostraram porcentagens semelhantes de coincidência de áreas (fundo branco), sendo 70% entre dVH e dNBR (Figura 45(a)), e 73% entre dVV e dNBR (Figura 45(b)). Os resultados também mostram que os produtos dVH e dVV identificaram mais áreas queimadas em comparação ao dNBR, 21% e 18%, respectivamente, ilustradas em magenta. As áreas classificadas como não queimadas nas diferenças SAR e queimadas na diferença dNBR foram de apenas 9%, em ambos os casos.

De forma geral, os resultados obtidos evidenciam a consistência e o potencial do uso de dados SAR na detecção de áreas queimadas. As análises indicaram que os modelos construídos utilizando as diferenças de retroespalhamento foram capazes de aprender e generalizar eficientemente padrões relevantes associados à presença de queimadas a partir de amostras extraídas com base em dados ópticos, apresentando desempenho satisfatório. Contudo, observou-se uma tendência à superestimação das áreas queimadas nas classificações baseadas em imagens SAR, independentemente da polarização utilizada (VV ou VH).

Além disso, a comparação entre as classificações reforçou a sensibilidade das imagens SAR às alterações estruturais causadas pelo fogo, o que se alinha às características físicas do sinal de Radar, especialmente sua resposta a mudanças na rugosidade da superfície e no teor de umidade da vegetação e do solo. Conforme apontado por Gibson *et al.* (2023), sensores SAR que operam em banda C são particularmente sensíveis à remoção de folhas, galhos e à alteração da estrutura do dossel, elementos frequentemente afetados por incêndios florestais. Isso permite que as imagens SAR identifiquem áreas com diferentes níveis de severidade de queimada, inclusive aquelas que não provocam forte contraste espectral nas imagens ópticas.


Por fim, os resultados demonstram a relevância da abordagem adotada e destacam a aplicabilidade de dados SAR em contextos de monitoramento ambiental, sobretudo em regiões com cobertura de nuvens frequente ou presença de fumaça persistente, onde a aquisição de dados ópticos pode ser limitada.

5.2 Áreas queimadas do PEEA detectadas pela segmentação semântica de atributos SAR

Esta seção apresenta os resultados obtidos no experimento que buscou avaliar o desempenho de uma rede de segmentação semântica U-Net na detecção de áreas queimadas em imagens SAR. A análise foi aplicada a um recorte de cena que engloba parcialmente o PEEA, afetado por eventos extremos de queimadas recorrentes, mas principalmente, aqueles ocorridos em 2020.

A anotação gerada semi-automaticamente a partir de dados ópticos, as previsões de áreas queimadas da rede U-Net referente ao conjunto de dados ópticos/SAR (σ_{VV}^0 , σ_{VH}^0 e σ_{HH}^0) e as previsões dos conjuntos de somente dados SAR (σ_{VV}^0 , σ_{VH}^0 e σ_{HH}^0), são apresentadas na Figura 46(a), (b), (c) e (d), respectivamente. Os pixels rotulados em vermelho se referem às áreas queimadas, enquanto o fundo branco indica áreas não afetadas pelo fogo.

Figura 46 - Dispersão espacial das áreas queimadas obtidas por meio de: (a) anotações geradas de forma semiautomática, a partir de limiar de alta severidade de fogo, máscara de água e filtro Sieve aplicados ao dNBR; (b) predição resultante da aplicação da rede U-Net aos conjuntos de dados ópticos/SAR e; (c) predição da U-Net com base em imagens SAR. Áreas indicadas em vermelho representam as queimadas.



Fonte: Marra *et al.* (2023)


As previsões obtidas com base nos dois conjuntos de dados apresentados na Figura 46(c) e (d) mostraram resultados espacialmente semelhantes à anotação gerada na Figura 46(b), embora tenham estimado uma maior extensão de áreas queimadas, indicando a presença de falsos positivos. Embora a anotação utilizada para treinar a rede U-Net tenha sido gerada a partir de um limiar elevado de severidade de queimada, os falsos positivos podem ser explicados pela alta sensibilidade das imagens SAR na detecção de áreas queimadas, mesmo de menor severidade.

Zhou *et al.* (2019) explica que o mecanismo dominante de retroespalhamento da vegetação antes do fogo é o espalhamento volumétrico da camada de dossel da vegetação. Durante um incêndio, à medida que a vegetação é queimada deixando parte do solo exposta, o mecanismo dominante se torna o espalhamento superficial, que depende principalmente da rugosidade e do teor de umidade do solo. Além disso, Mastro *et al.* (2022) e Tariq *et al.* (2021) afirmam que os coeficientes de retroespalhamento da banda C são capazes de detectar perturbações de fogo de forma eficiente devido à sua sensibilidade a mudanças na estrutura da vegetação afetada pelo fogo.

Portanto, considerando as características definidoras do sinal de retroespalhamento do Radar, como o teor de água e a rugosidade da superfície, as imagens SAR podem apresentar uma detecção mais sensível em comparação às imagens ópticas, uma vez que a ocorrência de queimadas, assim como de secas severas, pode alterar significativamente as propriedades dielétricas e a estrutura da vegetação.

Além das previsões espaciais de áreas queimadas, o processamento da rede resultou nas curvas de perda (função de Jaccard) e Acurácia, referentes ao treinamento e à validação dos dois conjuntos de dados (óptico/SAR e somente SAR), conforme apresentado na Figura 47.

Figura 47 - Curvas de Perda e Acurácia resultantes dos dados de treinamento e validação para (a e c) o conjunto de dados ópticos/SAR e (b e d) para o conjunto de dados SAR.



Fonte: Marra *et al.* (2023).

As curvas de perda e precisão apresentadas na Figura 47 indicam que os dados de validação de ambos os conjuntos se ajustaram adequadamente ao modelo, cujo desempenho se estabiliza após algumas dezenas de épocas. Além disso, as curvas de perda dos dados de validação (representadas em laranja na Figura 47(a) e (b)) convergem de forma contínua para zero, com pouca oscilação, sugerindo resultados consistentes. A métrica IoU, o tempo de processamento para cada conjunto de dados, bem como as áreas classificadas como queimadas em ambos os conjuntos e na anotação (expressas em hectares), são apresentados na Tabela 6.

Tabela 6 – Áreas classificadas como queimadas (em hectares), valores de IoU e tempo de processamento resultantes da aplicação da rede U-Net nos dois conjuntos de dados.

Dado	Área rotulada como queimada (ha)	IoU	Tempo de processamento
Anotação	54.789,44	-	-
Óptico/SAR	72.045,68	0.69	14'14"
SAR	79.200,20	0.60	14'12"

Fonte: Marra *et al.* (2023).

O conjunto de dados que combina imagens ópticas e SAR apresentou melhor desempenho, com uma IoU de 0,69. Em contrapartida, o conjunto contendo apenas dados SAR obteve uma IoU de 0,60. Além disso, ambos os conjuntos geraram resultados semelhantes quanto às áreas classificadas como queimadas e aos tempos de processamento, conforme detalhado na Tabela 6. O melhor desempenho do primeiro conjunto pode ser atribuído à inclusão do índice óptico NBR, desenvolvido especialmente para a detecção de áreas queimadas, que também foi utilizado no cálculo da diferença dNBR para a geração da anotação. Ainda assim, a diferença de IoU entre os dois conjuntos foi relativamente pequena, de apenas 0,09.

A correspondência entre predições e dados de referência em tarefas de detecção e segmentação de imagens tem sido considerada adequada quando o IoU é maior ou igual a 0,5 (EVERINGHAM *et al.*, 2010). Nesse sentido, os valores de IoU obtidos (0,60 e 0,69) indicam uma sobreposição consistente entre as áreas queimadas preditas e as áreas de referência, especialmente considerando o tamanho reduzido do conjunto de dados, a diferença entre os sensores utilizados (dados SAR e ópticos), bem como a variabilidade das características da vegetação nas áreas analisadas. Esses resultados demonstram consistência e evidenciam o potencial do uso exclusivo de dados SAR na detecção de áreas queimadas, mesmo quando comparado ao uso combinado de dados ópticos e SAR.

5.3 Impacto das queimadas de 2020 sobre os tipos de uso e cobertura da terra do PEEA a partir de imagens SAR


Nesta seção, são apresentados os resultados do experimento conduzido conforme a metodologia descrita na seção 4.4.4. O estudo teve como objetivo quantificar o impacto das queimadas ocorridas em 2020 sobre os diferentes tipos de uso e cobertura da terra na UC PEEA, identificando as classes mais suscetíveis à ação do fogo. A abordagem adotada incluiu uma análise do desempenho de diferentes algoritmos de classificação baseados

em ML, integrados ao ambiente do GEE, utilizando exclusivamente dados SAR, os quais subsidiaram a identificação e a quantificação das áreas afetadas.

As imagens provenientes da missão Sentinel-1 foram acessadas por meio da coleção “COPERNICUS/S1_GRD na plataforma GEE, tanto para o período pré quanto para o período pós-fogo (tomadas em 27 de julho e 24 de novembro de 2020, respectivamente) e encontram-se no formato GRD, já processadas com as correções necessárias e expressas em valores de retroespalhamento em decibéis (dB).

A partir das imagens SAR, foram calculados os índices polarimétricos CR, RVI, DPSVI, NRPB, DPDD e PA (Tabela 3), para as imagens pré e pós-fogo e, em seguida, foram obtidas as imagens diferença entre os períodos, para os coeficientes de retroespalhamento σ_{VH}^0 e σ_{VV}^0 (dVV, dVH) bem como para os índices polarimétricos (dCR, dRVI, dDPSVI, dNRPB, dDPDD e dPA). A Figura 48 apresenta as imagens geradas para os atributos SAR.

Figura 48 - Imagens SAR diferença temporal dos atributos VV e VH e dos índices polarimétricos CR, RVI, DPSVI, NRPB, DPDD e PA. Os atributos foram extraídos das diferenças entre imagens SAR tomadas em 27 de julho (pré-fogo) e 24 de novembro de 2020 (pós-fogo).



Fonte: Elaborado pela autora.

As imagens SAR diferença obtidas (Figura 48) foram utilizadas para classificar áreas queimadas e não queimadas na área de estudo, por meio dos algoritmos de aprendizado de máquina: RF, SVM, CART e KNN. Após o treinamento, os modelos foram avaliados com base nos 20% dos dados anotados, por meio das métricas de

acurácia: AG, coeficiente Kappa, *F-Score* e Matriz de Confusão, conforme apresentado na Tabela 7.

Tabela 7 - Métricas de acurácia resultantes das classificações dos algoritmos baseados em ML testados. Cl. refere-se ao resultado da classificação e Ref. é a referência.

Algoritmo	AG	Kappa	<i>F-Score</i>		Matriz de confusão			
			Não queim.	Queim.				
RF	0,8977	0,79997	0,8956	0,8997		Ref.		
					Cl.		NQ	Q
						NQ	3714	397
						Q	469	3882
SVM	0,8639	0,7277	0,8655	0,8628		Ref.		
					Cl.		NQ	Q
						NQ	3740	548
						Q	614	3655
CART	0,8605	0,7211	0,8618	0,8583		Ref.		
					Cl.		NQ	Q
						NQ	3752	591
						Q	602	3612
KNN	0,8819	0,7637	0,8831	0,8805		Ref.		
					Cl.		NQ	Q
						NQ	3820	477
						Q	534	3726

Fonte: Elaborado pela autora.

Os resultados apresentados na Tabela 7 indicam um desempenho semelhante entre os algoritmos avaliados. O RF apresentou valores ligeiramente superiores de AG (89,77%), coeficiente Kappa (0,79997) e *F-Score* (0,8956). A matriz de confusão também reflete esse comportamento, com o RF apresentando menor número de classificações incorretas em relação aos demais algoritmos, tanto para áreas queimadas quanto para não queimadas.

Em sequência, o algoritmo KNN apresentou desempenho próximo ao observado para o RF, atingindo uma AG de 88,19%, Kappa de 0,7637 e *F-Score* de 0,8831. Embora tenha apresentado um número levemente superior de erros de classificação em comparação ao RF, seus resultados sugerem uma alternativa viável na classificação das classes.

Os algoritmos SVM e CART apresentaram métricas ligeiramente inferiores em comparação ao RF e KNN. O SVM alcançou uma AG de 86,39%, com Kappa de 0,7277 e *F-Score* de 0,8655. O CART, obteve os menores índices entre os métodos testados, com AG de 86,05%, Kappa de 0,7211 e *F-Score* de 0,8618. Esses resultados indicam um maior número de classificações incorretas, particularmente na identificação de áreas queimadas.

A partir dos dados de validação, foi extraído, com base no algoritmo RF, o *ranking* de importância dos atributos utilizados na classificação. Essa análise permitiu identificar as variáveis com maior contribuição para a distinção entre áreas queimadas e não queimadas. Os resultados estão apresentados na Tabela 8.

Tabela 8 - *Ranking* de importância dos atributos extraído do algoritmo RF na classificação das áreas queimadas e não queimadas, baseado nos dados de validação.


Atributo	Porcentagem (%)
dVH	14,082
dVV	13,123
dDPDD	12,887
dPA	12,661
dDPSVI	11,971
dNRPB	11,816
dRVI	11,794
dCR	11,665

Fonte: Elaborado pela autora.

O *ranking* de importância dos atributos apresentados na Tabela 8 mostra uma distribuição relativamente equilibrada entre as variáveis utilizadas na classificação. O atributo dVH apresentou a maior contribuição (14,082%), seguido por dVV (13,123%), dDPDD (12,887%) e PA (12,661%), indicando que as bandas SAR polarizadas (VH e VV), assim como os índices DPDD e PA, desempenham um papel importante na diferenciação entre áreas queimadas e não queimadas. Os demais atributos, dPA, dDPSVI, dNRPB, dRVI e dCR, também demonstraram importância significativa, todos com valores acima de 11%, o que evidencia uma contribuição equilibrada entre variáveis SAR.

Em seguida, foi realizado o cálculo da medida IoU entre as áreas queimadas detectadas pelos algoritmos e aquelas mapeadas pelo Projeto MapBiomias – Monitor do Fogo. Contudo, antes dessa etapa, foi necessário aplicar a máscara d'água nas áreas queimadas provenientes do Monitor do Fogo. Essa etapa foi realizada devido à observação de corpos d'água classificados como áreas queimadas, conforme ilustrado na Figura 49.

Figura 49 - Áreas queimadas por tipo de uso e cobertura do solo e por mês, geradas a partir da intersecção dos produtos do Projeto MapBiomias, referentes ao ano de 2020: tipos de uso e cobertura do solo da Coleção Beta e dados de áreas queimadas do Monitor do Fogo. FF se refere à Formação Florestal, FS à Formação Savânica, CAAP à Campo Alagado e Área Pantanosa, FC à Formação Campestre e P à Pastagem.



Fonte: Elaborado pela autora com dados do Projeto Mapbiomas – Coleção Beta (2025) e Projeto Mapbiomas - Monitor do Fogo (2025)

Após a aplicação da máscara d'água, foi realizado o cálculo do IoU, permitindo avaliar o grau de sobreposição entre as áreas queimadas detectadas pelos algoritmos e aquelas identificadas pelo Monitor do Fogo. A Tabela 9 exibe os valores do IoU, além da área total classificada como queimada por cada algoritmo, expressa em km².

Tabela 9 - IoU e área total classificada como queimada referente aos algoritmos ML testados.

Algoritmo	IoU	Área total (km ²)
RF	0,614	636,273
SVM	0,581	604,030
CART	0,580	605,001
KNN	0,600	614,007


Fonte: Elaborado pela autora.

A Tabela 9 mostra que, entre os métodos analisados, o RF obteve o maior IoU (0,614), seguido pelo KNN com 0,600, enquanto SVM e CART apresentaram os menores valores, ambos em torno de 0,58. Além disso, ao comparar a área total classificada como queimada, observa-se que todos os algoritmos superestimaram a extensão das queimadas em relação ao produto de referência (MapBiomias - Monitor do Fogo de 2020), em torno de 505 km². O RF indicou a maior área queimada (636,273 km²) entre os algoritmos, seguido pelo KNN (614,007 km²), SVM (604,030 km²) e CART (605,001 km²).

Esse comportamento pode estar relacionado às características próprias das imagens de Radar na detecção de áreas queimadas. Gibson *et al.* (2023) afirmam que mudanças estruturais, como remoção de folhas e galhos no dossel da vegetação devido a queimadas, tem influência direta observada na resposta de retroespalhamento de banda C. Somado a isso, fatores como a constante dielétrica da vegetação, diretamente relacionada ao seu conteúdo hídrico, e as condições de seca extrema de 2020 que marcaram o período analisado no experimento, podem ter sido determinantes para a detecção de maiores áreas com base nos dados SAR. Finalmente, é importante destacar que, embora amplamente utilizados como referência, os produtos do Projeto MapBiomass são predominantemente derivados de dados ópticos, enquanto o presente estudo baseia-se em dados SAR. As diferenças nas propriedades físicas captadas por esses sensores (refletância espectral no caso de dados ópticos e retroespalhamento no caso do Radar) podem resultar em respostas distintas para áreas queimadas.


Os resultados apresentados indicam que o RF foi a abordagem mais eficiente na detecção das áreas queimadas, embora os demais algoritmos tenham demonstrado desempenhos semelhantes. Dessa forma, foi elaborado um mapa temático representando a distribuição espacial das áreas classificadas como queimadas pelo modelo (Figura 50). Além disso, essas áreas foram categorizadas de acordo com os tipos de uso e cobertura do solo, por meio da interseção dos resultados obtidos com os dados da Coleção Beta do MapBiomass 10 metros, referentes ao ano de 2020 (Figura 51).

Figura 50 - Área total queimada obtida a partir do modelo RF no PEEA, destacada em vermelho.



Fonte: Elaborado pela autora.

Figura 51 - Área queimada resultante da aplicação do modelo RF por tipo de uso e cobertura do solo, obtida por meio da intersecção com dados do Projeto Mapbiomas – Coleção Beta. FF se refere à Formação Florestal, FS à Formação Savânica, CAAP à Campo Alagado e Área Pantanosa, FC à Formação Campestre e P à Pastagem.



Fonte: Elaborado pela autora.

A Figura 51 mostra que a maior proporção de área queimada corresponde à Formação Campestre (FC), representando 49,6% do total, seguida pela Formação Savânica (FS) com 25,6% e pela Formação Florestal (FF) com 21,2%. Campo Alagado e Área Pantanosa (CAAP) e a Pastagem (P) tiveram as menores áreas afetadas, com 3,0% e 0,6%, respectivamente.

A alta incidência de áreas queimadas na classe FC pode estar relacionada à predominância de gramíneas secas (ver descrição no Quadro 1), que tornam essa vegetação mais suscetível ao fogo. Segundo Silva (2018), a abundância de material combustível fino e contínuo nesse tipo de formação favorece a rápida propagação das chamas, cuja intensidade varia conforme a umidade do material combustível, condições meteorológicas e topografia do terreno. O autor também afirma que as formações campestres, seguidas das savânicas, apresentam maior propagação e intensidade do fogo, liberando mais calor e carbono, além de apresentarem maior consumo de combustível fino e eficiência na combustão, quando comparadas às formações florestais.


5.4 Evolução da vegetação natural nas áreas queimadas do PEEA por meio de atributos polarimétricos SAR

A dinâmica temporal e os impactos das queimadas sobre os diferentes tipos de uso e cobertura do solo na área de estudo, foram caracterizados por meio de séries temporais mensais de dados SAR e ópticos, complementadas pelas variáveis meteorológicas precipitação e temperatura, abrangendo o período de janeiro de 2019 a dezembro de 2024.

A primeira etapa da metodologia concebida para esta abordagem consistiu na seleção dos atributos SAR a serem monitorados ao longo da série temporal. Como base para essa seleção, foi analisado o *ranking* de importância dos atributos SAR extraídos pelo algoritmo RF (Tabela 8), que apresentou o melhor desempenho na classificação de áreas queimadas e não queimadas, conforme apresentado na seção 5.3. Além disso, foi avaliada a separabilidade entre essas classes, calculada individualmente para cada atributo SAR considerado: σ_{VH}^0 , σ_{VV}^0 , CR, RVI, DPSVI, NRPB, DPDD e PA.

A Figura 52 ilustra graficamente a separabilidade entre as classes para cada um desses atributos, enquanto a Tabela 10 apresenta os valores médios obtidos para áreas queimadas e não queimadas, assim como as respectivas diferenças entre essas médias.

Figura 52 - Média dos valores dos pixels referentes às amostras de áreas queimadas e não queimadas, representadas em triângulo vermelho e círculo verde, respectivamente, para σ_{VH}^0 e σ_{VV}^0 e índices polarimétricos CR, RVI, DPSVI, NRPB, DPDD e PA. Os valores foram extraídos a partir de uma imagem SAR adquirida em 24 de novembro de 2020, posterior ao evento de fogo.



Fonte: Elaborado pela autora.

Tabela 10 - Valores médios dos pixels referentes às amostras de áreas queimadas e não queimadas, dos coeficientes de retroespalhamento σ_{VH}^0 e σ_{VV}^0 e índices polarimétricos CR, RVI, DPSVI, NRPB, DPDD e PA. As médias foram extraídas a partir da imagem SAR adquirida em 24 de novembro de 2020, posterior ao evento de fogo.

Atributo	Média das amostras de área queimada (dB)	Média das amostras de área não queimada (dB)	Diferença (dB)
VH	-21,061	-13,512	-7,549
VV	-12,605	-8,158	-4,447
CR	0,604	0,608	-0,003
RVI	2,502	2,503	-0,001
DPSVI	2,696	2,718	-0,022
NRPB	0,251	0,251	-0,001
DPDD	-5,979	-3,786	-2,193
PA	-4,228	-2,677	-1,551

Fonte: Elaborado pela autora.

Com base na Figura 52 e na Tabela 10, é possível observar que a separabilidade entre áreas queimadas e não queimadas apresenta variações expressivas entre os atributos SAR analisados. Os atributos VH e VV apresentaram as maiores diferenças entre as médias das classes ($-7,549$ dB e $-4,447$ dB, respectivamente), evidenciando maior eficácia na distinção entre as áreas, em comparação aos demais atributos. Já os atributos DPDD ($-2,19$ dB) e PA ($-1,55$ dB) também demonstraram capacidade de distinção relevante, embora em menor grau. Por outro lado, os índices CR, RVI, DPSVI e NRPB

apresentaram diferenças próximas de zero entre as médias das classes, indicando baixa separabilidade.

Além disso, os resultados apresentados na Tabela 8, que apresenta o *ranking* de importância dos atributos SAR gerado pelo classificador RF, confirmam a maior capacidade de discriminação entre as classes pelos atributos VH, VV, DPDD e PA. Dessa forma, esses quatro atributos foram selecionados para o acompanhamento ao longo do tempo nas séries temporais, por apresentarem maior potencial para representar a dinâmica das áreas queimadas na região de estudo.


5.4.1 Análise de séries temporais dos índices ópticos NDVI e NBR e SAR σ_{VH}^0 , σ_{VV}^0 , DPDD e PA

A partir da definição dos atributos SAR, a área de monitoramento foi delimitada pela intersecção entre a classificação de áreas queimadas no PEEA gerada pelo classificador RF e os dados do MapBiomass – Monitor do Fogo de 2020. Essa área ainda foi segmentada por tipos de uso e cobertura do solo definidos pela Coleção Beta do MapBiomass também de 2020, permitindo o cálculo mensal da média e do desvio padrão dos atributos SAR selecionados, além dos índices NDVI e NBR.

Para o cálculo dos valores mensais de média e desvio padrão dos atributos definidos, foram acessadas 177 imagens SAR do sensor Sentinel-1 e 226 imagens ópticas do Sentinel-2 por meio das coleções do GEE, abrangendo o período de janeiro de 2019 a dezembro de 2024, conforme listadas no Quadro 4 e Quadro 5.

Para auxiliar na análise das séries temporais, foi elaborada a Figura 53 com base nos dados do projeto MapBiomass – Monitor do Fogo, representando a extensão e a distribuição espacial das áreas queimadas no PEEA entre os anos de 2019 e 2024, período que corresponde à abrangência da série temporal considerada neste estudo. A área total queimada é indicada em cada painel, e os gráficos circulares mostram a porcentagem relativa da área queimada por mês. As maiores concentrações de queimadas são observadas nos anos de 2020, 2023 e 2024, com destaque para os meses de setembro e outubro. Em 2022, não houve registros significativos de queimadas na área de estudo.


Figura 53 - Distribuição espacial das áreas queimadas no PEEA entre 2019 e 2024, com base nos dados do Projeto MapBiomias – Monitor do Fogo.



Fonte: Elaborado pela autora com dados do Projeto MapBiomias - Monitor do Fogo (2025).


Em seguida, são apresentadas as séries temporais dos índices ópticos NDVI (Figura 54) e NBR (Figura 55), para fins de comparação, discriminando os tipos de uso e cobertura do solo identificados na área de estudo (Pastagem – P, Campo Alagado e Área Pantanosa – CAAP, Formação Florestal – FF, Formação Savânica – FS e Formação Campestre – FC). As barras azuis representam os valores mensais médios de precipitação (em mm), a linha tracejada vermelha indica a temperatura média mensal (°C), e abaixo de cada série temporal, é indicada a divisão entre períodos chuvosos (em azul claro) e períodos de seca (em bege claro).

Figura 54 - Perfis temporais da média (a) e do desvio padrão (b) mensais do índice espectral óptico NDVI.



Fonte: Elaborado pela autora.

Figura 55 - Perfis temporais da média (a) e do desvio padrão (b) mensais do índice espectral óptico NBR.



Fonte: Elaborado pela autora.

Os perfis temporais do NDVI mostrados na Figura 54 indicam que esse índice, sensível à densidade e ao vigor da vegetação, apresentou um comportamento sazonal bem estabelecido, com valores ascendentes durante o período chuvoso, e valores decrescentes na estação seca. As classes Formação Florestal (FF) e Formação Savânica (FS) registraram os maiores valores médios de NDVI, compatíveis com a estrutura densa e maior acúmulo de biomassa pela vegetação. A amplitude das médias mensais foi de

aproximadamente 0,70 para FF e 0,69 para FS, enquanto os valores médios de desvio padrão foram de 0,27 e 0,22, respectivamente (Figura 54(a)).

As classes Formação Campestre (FC) e FS apresentaram reduções expressivas, especialmente no ano de 2020, marcado por uma queimada severa na área de estudo. Nesse ano, FC atingiu o valor mínimo de toda a série temporal, com aproximadamente 0,12 no mês de outubro. FS apresentou um comportamento semelhante, com valor médio mínimo em torno de 0,16 no mesmo mês. A classe Campo Alagado e Área Pantanosa (CAAP) registrou um valor mínimo próximo ao da FS, enquanto a classe Pastagem (P) apresentou um valor ligeiramente inferior ($\sim 0,15$), evidenciando o impacto dos distúrbios causados pelas queimadas sobre essas coberturas florestais sensíveis.

Ao observar o gráfico do desvio padrão (Figura 54(b)), é possível perceber que os maiores valores ocorrem principalmente durante as estações chuvosas, especialmente nos meses de janeiro a março. Esse comportamento é consistente ao longo de todos os anos. Os maiores desvios padrões observados nas classes foram: FF (0,31), FC (0,28), FS (0,27), CAAP (0,25), e P (0,21), sendo CAAP a cobertura da terra de maiores valores de desvio padrão ao longo da série temporal.

Os perfis temporais do NBR (Figura 55), índice tradicionalmente usado para detecção de áreas queimadas, mostraram uma queda acentuada nas médias mensais em 2020 (Figura 55(a)), ano de queimadas severas na área de estudo, refletindo a perda de biomassa e exposição do solo. Essa queda foi observada em todas as classes de cobertura, com destaque para FC e P, que atingiram médias mínimas de $\sim -0,27$ em outubro e novembro. A classe CAAP apresentou valores próximos ($\sim -0,26$), enquanto FF e FS registraram -0,17 e -0,23, respectivamente.

Todas as classes demonstraram sensibilidade às queimadas, com reduções expressivas nos valores de NBR logo após os eventos, seguidas por um padrão de recuperação gradual nos meses seguintes. No entanto, as classes FC, CAAP e P indicaram uma recuperação mais rápida em 2020, em comparação às classes FF e FS. Embora apresentassem valores absolutos mais elevados no início da série temporal até o evento de queimada de 2020, FF e FS sofreram perdas mais persistentes ao longo do tempo, indicando um processo de recuperação estrutural mais lento.

Esse comportamento reflete diferentes capacidades de regeneração entre os tipos de cobertura, influenciadas tanto pela severidade das queimadas quanto pelas condições climáticas subsequentes. Formações florestais, como FF e FS, tendem a apresentar um processo de regeneração mais lento em relação a formações abertas ou pastagens, devido

à sua estrutura mais complexa e ao ciclo de vida mais longo das espécies. Além disso, o fogo pode comprometer processos essenciais de recuperação, prolongando o tempo necessário para a recuperação.


A classe Pastagem também evidenciou variações pontuais, possivelmente associadas a atividades antrópicas e à rápida regeneração da vegetação herbácea, especialmente nos períodos chuvosos entre 2020-2021 e 2021-2022. Por sua vez, a classe CAAP, ainda que relacionada a áreas úmidas, respondeu de forma semelhante às demais, evidenciando sensibilidade aos impactos do fogo.

O desvio padrão dos valores de NBR (Figura 55(b)) também revelou aspectos importantes sobre os efeitos das queimadas. As classes CAAP e FC apresentaram aumentos expressivos nos valores de desvio padrão, especialmente durante as estações chuvosas. Esse comportamento indica maior heterogeneidade nas áreas afetadas, sugerindo variações locais no grau de impacto do fogo, na regeneração e na disponibilidade hídrica.

Contudo, destaca-se a presença de lacunas (falhas) nas séries temporais ópticas, especialmente nos meses chuvosos, em que a presença de nuvens e alta umidade atmosférica comprometem a aquisição de imagens de qualidade. Essas interrupções dificultam o monitoramento contínuo por sensores ópticos e a interpretação detalhada do comportamento da vegetação durante partes importantes do ciclo hidrológico.


Na sequência da análise temporal, são apresentadas as séries temporais geradas para os atributos SAR selecionados: σ_{VH}^0 (Figura 56), σ_{VV}^0 (Figura 57), DPDD (Figura 58) e PA (Figura 59).

Figura 56 - Perfis temporais da média (a) e do desvio padrão (b) mensais do coeficiente de retroespalhamento SAR σ_{VH}^0 .




Fonte: Elaborado pela autora.

Figura 57 - Perfis temporais da média (a) e do desvio padrão (b) mensais do coeficiente de retroespalhamento SAR σ_{VV}^0 .




Fonte: Elaborado pela autora.

Figura 58 - Perfis temporais da média (a) e do desvio padrão (b) mensais do índice polarimétrico SAR PA.



Fonte: Elaborado pela autora.

Figura 59 - Perfis temporais da média (a) e do desvio padrão (b) mensais do índice polarimétrico SAR DPDD.



Fonte: Elaborado pela autora.

O comportamento dos coeficientes de retroespalhamento SAR Sentinel-1 σ_{VH}^0 e (Figura 56) e σ_{VV}^0 (Figura 57) ao longo da série temporal, evidencia uma dinâmica marcadamente sazonal nas principais classes de uso e cobertura do solo do PEEA, compatível com a dinâmica hidrológica do bioma Pantanal.

Ambas as polarizações VH e VV mostraram alta sensibilidade às queimadas, refletindo a influência da estrutura da vegetação e da umidade nos diferentes tipos de uso

e cobertura na resposta do Radar. Todas as classes apresentaram redução nos valores médios ao final da estação seca, especialmente em anos com maior ocorrência de fogo. Em 2019 e 2022, com queimadas menos intensas ou ausentes (Figura 53), as quedas foram mais suaves, ainda que com oscilações, reforçando o papel da umidade na variação do sinal SAR.

Na Figura 56(a), observa-se que, durante o ano crítico de 2020, ocorreu uma queda acentuada nos valores de VH, especialmente nas classes CAAP e FC, que registraram os menores valores de toda a série temporal, ambos com valores médios mínimos de aproximadamente -21 dB. Além disso, VH também apresentou reduções visíveis nos períodos de queimada dos anos de 2021 e 2023, com destaque também para as classes CAAP e FC. Em 2024 houve um comportamento diferente em relação aos demais períodos da série temporal, com quedas significativas nas classes FF e FS, evidenciando perda estrutural da vegetação das classes. As quedas apresentadas ao longo da série acompanham os picos de temperatura e baixa precipitação nos meses que antecedem.

Ao longo da série temporal, as classes FF e FS mostraram variações menos intensas, com quedas mais suaves após queimadas, em relação às demais classes. Esse comportamento sugere menor impacto na estrutura detectada pelo retroespalhamento VH, possivelmente devido ao maior conteúdo de água e biomassa, característicos dessas formações (Quadro 1). Dessa forma, mesmo com perdas parciais na cobertura vegetal, a vegetação remanescente pode suavizar as variações no retroespalhamento.

A classe Pastagem, por sua vez, apresentou alta variabilidade ao longo da série temporal, com valores elevados em períodos chuvosos e quedas abruptas associadas a queimadas, evidenciando sua sensibilidade sazonal. Esse padrão reflete a natureza dinâmica das pastagens, que respondem rapidamente às condições climáticas e ao fogo, com impacto imediato, mas também rápida regeneração.

Os valores de desvio padrão apresentados na Figura 56(b) indicam variações mais significativas ao final dos períodos de seca, com destaque para as classes CAAP e FC, especialmente nos anos de 2020, 2021 e 2023. Os maiores valores foram registrados em novembro de 2023: 4,30 dB para CAAP e 3,66 dB para FC, refletindo grande variação estrutural local durante os eventos de queimada. A classe P apresentou comportamento intermediário, com desvio padrão máximo de 2,78 dB em outubro de 2020. As classes FF e FS mantiveram variações mais sutis ao longo da série temporal, com pequenas

oscilações registradas principalmente nos anos de 2020, 2023 e 2024, indicando uma resposta mais estável às condições climáticas e ao fogo.

O coeficiente de retroespalhamento σ_{VV}^0 apresentou padrões temporais semelhantes ao σ_{VH}^0 , com quedas nos anos de queimada severa e recuperação parcial nos anos seguintes (Figura 57 (a)). No entanto, o VH mostrou maior amplitude de variação (-22 dB a -12 dB) em comparação ao VV (-14 dB a -7 dB), com uma diferença de cerca de 3 dB. Essa diferença reforça a maior sensibilidade do canal VH às alterações estruturais provocadas pelo fogo, especialmente à perda de biomassa aérea. Por operar em polarização cruzada, o VH é mais sensível a elementos tridimensionais da vegetação, como folhas e galhos finos, componentes que são rapidamente consumidos pelo fogo, o que o torna mais eficaz na detecção de distúrbios abruptos na densidade e na estrutura vegetal (PATEL *et al.*, 2006).

Em 2019 e 2022, as polarizações VV e VH apresentaram comportamento mais estável, sem quedas significativas, refletindo a ocorrência de queimadas de menor intensidade ou ausência desses eventos no PEEA, conforme dados do MapBiomias (Figura 53). Durante a queimada de 2020, o retroespalhamento VH apresentou queda ligeiramente anterior e mais rápida que o VV, indicando maior sensibilidade imediata ao fogo. Além disso, o VH também mostrou recuperação mais rápida, possivelmente relacionada à regeneração inicial da biomassa herbácea e de pequenos ramos.

A evolução do desvio padrão médio mensal do coeficiente de retroespalhamento σ_{VV}^0 (Figura 57(b)) evidenciou alta variabilidade temporal entre as classes de uso e cobertura do solo, especialmente nos anos críticos de 2020, 2021, 2023 e 2024. As classes CAAP e FC apresentaram os maiores picos: 3,00 dB em outubro de 2021 (CAAP) e 2,80 dB em setembro de 2020 (FC), refletindo a heterogeneidade causada por queimadas intensas.

A classe P também registrou variações expressivas, atingindo seu maior desvio padrão de 2,35 dB em maio de 2023. Esse pico contrasta com o comportamento geral da série, cujo aumento dos valores de desvio padrão geralmente ocorre na estação seca. Esse comportamento também foi observado no canal VH, porém com menor intensidade, sugerindo uma resposta diferenciada da pastagem às condições ambientais desse período.

Em contraste, as classes FF e FS mantiveram desvios padrão mais estáveis, próximos de 1,5 dB, mesmo durante as queimadas de 2020 e 2021. No entanto, registraram picos em 2023 e 2024, com valores próximos de 2,30 dB. Esse comportamento é compatível com a estrutura mais densa e estável dessas formações

florestais, que tendem a responder de forma mais homogênea às variações sazonais e a distúrbios, padrão que também se repete na polarização VH.

Os perfis temporais de VH e VV mostram comportamentos semelhantes, mas com diferenças de amplitude que destacam a maior capacidade do retroespalhamento VH em detectar a intensidade e extensão das alterações causadas pelas queimadas, tornando-o um indicador mais eficiente para monitoramento. Embora ambos sejam afetados por fatores ambientais como sazonalidade e seca, o VV apresenta menor variação, sugerindo menor sensibilidade a mudanças volumétricas. Ainda assim, VV pode ser um importante complemento na análise, especialmente nas fases de recuperação, ao captar o recobrimento por vegetação rasteira. A análise combinada das duas polarizações oferece uma compreensão mais completa dos impactos e da regeneração da vegetação após o fogo.

Ambos os índices polarimétricos SAR PA (Figura 58) e DPDD (Figura 59) apresentam uma evolução temporal muito semelhante ao longo dos anos, com quedas, principalmente, ao final de períodos secos, se alinhando com os padrões de recuperação do bioma Pantanal. No entanto, nota-se uma leve diferença na amplitude das variações entre os índices: enquanto o PA varia aproximadamente entre -4,10 dB e -2,20 dB (Figura 58 (a), amplitude de 1,90 dB), o DPDD oscila entre -5,80 dB e -3,20 dB (Figura 59 (a), amplitude de 2,60 dB).

Os índices PA e DPDD acompanham um padrão sazonal semelhante, com reduções mais acentuadas nos anos de maior distúrbio, como em 2020, por exemplo. O DPDD, no entanto, tende a apresentar valores mínimos ligeiramente mais pronunciados nesses períodos, refletindo sua sensibilidade a alterações abruptas na estrutura da vegetação.

As classes de uso e cobertura apresentaram respostas distintas ao longo do tempo nos índices polarimétricos em relação aos coeficientes de retroespalhamento. As classes CAAP e FC foram as que mais sofreram com as queimadas, apresentando as maiores sensibilidades entre as classes, com variações expressivas tanto na média quanto no desvio padrão, especialmente em 2020, ano com distúrbio mais intenso. No PA, as amplitudes na média chegaram a aproximadamente 1,80 dB para CAAP e 1,60 dB para FC (Figura 58 (a)), enquanto no desvio padrão os valores foram de cerca de 0,44 dB e 0,37 dB (Figura 58 (b)), para CAAP e FC, respectivamente. Em DPDD, as amplitudes da média alcançaram aproximadamente 2,50 dB para CAAP e 2,20 dB para FC (Figura 59 (a)), com variações no desvio padrão em torno de 0,60 dB e 0,50 dB (Figura 59 (b)).

A classe FC, caracterizada por uma vegetação herbácea dominada por gramíneas, é naturalmente mais suscetível ao fogo devido à sua estrutura mais fina e inflamável. De forma semelhante, a classe CAAP, composta por vegetação herbácea, porém sujeita a alagamentos permanentes ou temporários (Quadro 1), também apresentou alta vulnerabilidade. Embora essas áreas sejam tipicamente úmidas, a redução observada após os períodos de seca indica que as condições hidrológicas podem ter sido alteradas temporariamente, favorecendo a ocorrência e propagação do fogo.

A classe P apresentou comportamento intermediário, com amplitude de aproximadamente 1,60 dB na média e 0,26 dB no desvio padrão em PA (Figura 58 (a e b)) e 2,26 dB e 0,36 dB, respectivamente, em DPDD (Figura 59 (a e b)). Apesar de valores semelhantes ou superiores aos da classe FC, a série temporal de P mostrou menor variabilidade, com picos isolados, indicando menor sensibilidade a perturbações.

FS e FF apresentaram comportamento mais estável, com menores amplitudes nos valores de média e desvio padrão, indicando menor sensibilidade a distúrbios. Em PA, ambas as classes tiveram amplitude média de cerca de 1,00 dB, com desvio padrão de 0,22 dB (FS) e 0,18 dB (FF) (Figura 60 (a e b), respectivamente). Em DPDD, FS alcançou 1,50 dB na média e 0,32 dB no desvio padrão, enquanto FF registrou 1,40 dB e 0,25 dB, na média e desvio padrão, respectivamente (Figura 59 (a e b)). A classe FF se destacou como a mais estável, com baixas variações ao longo da série temporal.

De modo geral, o desvio padrão médio mensal dos índices PA e DPDD tende a aumentar em anos com queimadas, especialmente nas classes CAAP e FC. Esse padrão reflete um aumento na heterogeneidade espacial das áreas afetadas, indicando variações locais no grau de impacto do fogo, nos estágios de regeneração da vegetação e nas condições de umidade. A semelhança entre os índices mostra que ambos são eficazes na detecção de mudanças estruturais na vegetação, mas a maior amplitude do DPDD indica sua maior sensibilidade a alterações abruptas ao longo do tempo.

A análise conjunta das séries temporais e variáveis climáticas indica forte correlação entre os períodos de seca prolongada, temperaturas elevadas e a ocorrência das queimadas, principalmente nos anos de 2020, 2021, 2023 e 2024. A vegetação afetada apresentou sinais de regeneração nos meses seguintes aos incêndios, evidenciados por aumentos graduais em todas as variáveis ópticas e SAR. Essa regeneração foi mais rápida nas classes FC, P e CAAP, e mais lenta e gradual nas formações FF e FS, sugerindo diferenças estruturais no processo de recomposição vegetal.

A precipitação e a temperatura exibiram padrões anuais típicos do bioma, com chuvas concentradas, geralmente entre outubro e abril e estação seca de maio a setembro. Os eventos de queimada coincidiram com períodos de estiagem prolongada e temperaturas elevadas, criando condições favoráveis à propagação do fogo. A correlação temporal entre os extremos climáticos e as reduções nos índices ópticos e SAR reforça a influência direta do clima sobre a dinâmica da vegetação e a ocorrência de queimadas.

Com base na análise temporal dos dados SAR e ópticos, foi possível identificar padrões claros de resposta das diferentes classes de cobertura vegetal frente aos distúrbios causados pelo fogo. Os dados SAR demonstraram desempenho consistente ao longo das séries temporais, permitindo identificar alterações associadas às queimadas com eficiência. O coeficiente de retroespalhamento σ_{VH}^0 se destacou por sua sensibilidade às modificações estruturais da vegetação, reforçando seu potencial no monitoramento de distúrbios ambientais.

Além disso, os índices polarimétricos DPDD e PA se mostraram eficazes no acompanhamento da regeneração da vegetação, revelando respostas diferenciadas entre as classes. As classes FC, FS e FF foram as mais sensíveis, com alterações expressivas nos padrões espectrais e de retroespalhamento, especialmente nos períodos críticos.

5.4.2 Análise das correlações entre índices ópticos e parâmetros SAR

Após a avaliação das séries temporais dos índices ópticos e dos parâmetros SAR, foi realizada a análise de correlação entre as respostas espectrais derivadas das imagens ópticas (NDVI e NBR) e dos atributos SAR (σ_{VV}^0 , σ_{VH}^0 , PA e DPDD), ao longo do período estudado. Essa etapa permitiu verificar o grau de correspondência temporal entre métricas que capturam propriedades distintas da vegetação, considerando os diferentes tipos de uso e cobertura do solo presentes no PEEA.

Para isso, foram calculados coeficientes de correlação de Pearson entre cada índice espectral e os atributos polarimétricos selecionados, utilizando as médias mensais previamente obtidas para cada classe. Os resultados dessa análise são apresentados na Tabela 11.

Tabela 11 – Coeficientes de correlação de Pearson entre os índices espectrais NBR e NDVI e os atributos SAR (σ_{VV}^0 , σ_{VH}^0 , PA e DPDD), calculados separadamente para cada classe de uso e cobertura do solo do PEEA.

Classe	NDVI				NBR			
	σ_{VV}^0	σ_{VH}^0	PA	DPDD	σ_{VV}^0	σ_{VH}^0	PA	DPDD
FF	0,8212	0,7993	-0,0181	-0,0181	0,8328	0,8231	0,0152	0,0152
FS	0,8438	0,8156	0,0517	0,1068	0,8767	0,8612	0,0979	0,1503
FC	0,8177	0,8235	0,3074	0,3074	0,9189	0,9284	0,3547	0,3547
CAAP	0,8081	0,7994	0,4110	0,4110	0,9177	0,9117	0,4770	0,4770
P	0,8337	0,7790	0,1583	0,1583	0,9189	0,8645	0,1453	0,1453

A Tabela 11 apresenta os valores de correlação entre os índices espectrais ópticos NDVI e NBR e os atributos polarimétricos SAR σ_{VV}^0 , σ_{VH}^0 , PA e DPDD, para as cinco classes analisadas (FF, FS, FC, CAAP e P). De maneira geral, observa-se que o NDVI mantém correlações consistentemente altas e positivas com σ_{VV}^0 e σ_{VH}^0 , variando entre 0,7790 e 0,8438, o que indica forte associação entre a resposta espectral do índice óptico e do retroespalhamento SAR na vegetação, especialmente em σ_{VV}^0 . Esse resultado sugere que, nas áreas avaliadas, a estrutura e a densidade da vegetação influenciam de forma semelhante os dois tipos de dados.

Por outro lado, as correlações entre o NDVI e os parâmetros PA e DPDD mostram maior variabilidade entre as classes. Enquanto FF e P apresentaram valores próximos de zero (-0,0181 e 0,1583, respectivamente), indicando fraca relação, as classes FC e CAAP registraram correlações mais elevadas (0,3074 e 0,4110, respectivamente).

Resultados semelhantes, porém, com amplitudes sutilmente maiores, são observados nas correlações obtidas entre o NBR e as variáveis SAR (Tabela 11). Os coeficientes σ_{VV}^0 e σ_{VH}^0 atingem valores ainda mais elevados (0,8231 a 0,9284), reforçando que esses atributos reproduzem padrões temporais similares aos observados para o NBR. Assim, a elevada correlação observada indica que esses parâmetros SAR conseguem acompanhar, de forma consistente, as variações capturadas, tanto pelo NBR, quanto pelo NDVI, evidenciando seu potencial como métricas alternativas para o mapeamento e monitoramento de áreas queimadas.

Com base no desempenho observado na análise de séries temporais dos índices ópticos NDVI e NBR e dos parâmetros SAR σ_{VV}^0 , σ_{VH}^0 , DPDD e PA (Seção 5.4.1), bem como nos resultados da análise de correlação, as classes FC e FS foram selecionadas para a aplicação do modelo de decomposição temporal BFAST. Essas classes apresentaram relações consistentes entre os índices ópticos e os parâmetros derivados do

retroespalhamento SAR, indicando forte coerência temporal entre variações espectrais e estruturais.


5.4.3 Análise de tendência, sazonalidade e identificação de quebras nas séries temporais por meio do modelo BFAST

Devido às descontinuidades nas séries temporais ópticas observadas em dezembro de 2022, fevereiro de 2023 e novembro de 2024, causadas por falhas de aquisição nas imagens Sentinel-2, foi necessária a interpolação dos dados espectrais para garantir a continuidade das séries. Essa etapa assegurou valores regulares ao longo do tempo, condição essencial para o funcionamento do BFAST e para a identificação precisa de quebras e tendências na vegetação.

Os valores ausentes nas séries temporais foram preenchidos por meio de interpolação linear utilizando a função `na.approx()` do pacote `zoo` (ZEILEIS; GROTHENDIECK, 2005) em linguagem R. A interpolação linear é uma técnica amplamente empregada para estimar valores intermediários em séries temporais contínuas, assumindo uma variação linear entre os pontos adjacentes observados. Após a interpolação, os valores da série foram visualizados para verificação da consistência do resultado.

As análises de tendência, sazonalidade e identificação de quebras nas séries temporais dos índices espectrais ópticos NDVI e NBR, realizadas por meio do modelo BFAST, são apresentadas na Figura 60. As colunas da figura correspondem às classes FC e FS, respectivamente, analisadas separadamente para cada índice óptico. A análise de cada índice para cada classe é organizada em três painéis horizontais: o primeiro mostra os valores médios mensais de cada variável ao longo do tempo (Y_i), enquanto os painéis inferiores trazem os resultados da decomposição das séries temporais de cada atributo e classe. St se refere à componente de sazonalidade e Tt aos pontos de quebra identificados na tendência geral, sendo β o coeficiente angular e p o valor de significância estatística (p-valor).

Figura 60 - Séries temporais dos atributos ópticos NDVI (a, b) e NBR (c, d) geradas para as classes FC e FS, bem como suas respectivas decomposições obtidas pelo algoritmo BFAST.



A decomposição das séries temporais do índice de vegetação NDVI por meio do algoritmo BFAST revelou comportamentos distintos entre as classes de uso e cobertura do solo FC (Figura 60 (a)) e FS (Figura 60 (b)) o período de janeiro de 2019 a dezembro de 2024.

Para a classe FC, foi observada uma tendência estável ao longo do período analisado, com uma inclinação mínima ($\beta = -0,001$) e sem significância estatística ($p = 0,294$). Além disso, a ausência de pontos de quebra na série temporal do NDVI sugere estabilidade ecológica dessa formação vegetal. Com uma componente sazonal consistente e padrões anuais bem definidos e regulares, observa-se que a classe FC reflete uma dinâmica bem ajustada às variações climáticas locais, embora marcada por baixa estatura e biomassa limitada.

Apesar da resposta cíclica bem estabelecida da classe FC, não foram identificados pontos de quebra na série temporal mesmo durante eventos de grande extensão de área queimada, como em 2020, conforme evidenciado pelos dados do MapBiomas - Monitor do Fogo (Projeto Mapbiomas - Monitor do Fogo, 2025; Figura 53). Esse comportamento indica que, mesmo diante de eventos extremos, a sazonalidade

regular e a resiliência das formações campestres podem mascarar mudanças abruptas na série temporal analisada.

Em contraste, a série temporal da classe FS apresentou uma dinâmica mais variável ao longo do período analisado. Embora a sazonalidade permaneça bem definida, o ciclo anual da FS revela que essa formação responde ao regime climático com maior variabilidade, exibindo flutuações interanuais mais acentuadas em sua tendência.

A tendência da classe apresentou três segmentos distintos, com quebras estruturais (pontos de quebra) identificadas nos anos de 2020 e 2022. No primeiro segmento (2019–2020), houve uma leve redução do NDVI ($\beta = -0,069$), porém sem significância estatística ($p = 0,183$). A seguir, entre 2020 e 2022, foi observada uma forte recuperação da vegetação ($\beta = 0,165$; $p = 0,000$), sugerindo processos de regeneração pós-distúrbio, possivelmente relacionados aos eventos de queimada ocorridos em 2020.

No último segmento (2022–2024), houve uma nova queda significativa na classe ($\beta = -0,146$; $p = 0,000$), indicando um novo impacto ou recorrência de distúrbios ambientais, como requeimas ou estresse hídrico. A detecção automatizada dessas mudanças estruturais na tendência da série é uma das principais vantagens do algoritmo BFAST, que permite identificar, de forma robusta, rupturas associadas a eventos antropogênicos ou naturais (VERBESSELT *et al.*, 2010).

A análise BFAST das séries temporais do índice espectral óptico NBR para as classes FC (Figura 60 (c)) e FS (Figura 60 (d)) revelou padrões distintos de perturbação e recuperação da vegetação.

A tendência da classe FC apresentou cinco segmentos distintos, separados por quatro pontos de quebra identificados entre 2019 e 2024. No primeiro segmento (2019 até o final de 2020), observou-se uma tendência levemente negativa ($\beta = -0,036$; $p = 0,315$), não estatisticamente significativa, indicando uma estabilidade relativa na dinâmica da vegetação. No segundo segmento (2020-2021), a tendência se tornou positiva ($\beta = 0,628$; $p = 0,191$), embora ainda sem evidência estatística robusta.

O terceiro segmento (2021-2022) apresentou uma tendência positiva expressiva ($\beta = 0,254$; $p = 0,000$), estatisticamente significativa, sugerindo uma recuperação consistente da vegetação campestre. No quarto segmento (final de 2022 até o final de 2023), houve uma leve tendência de queda ($\beta = -0,018$; $p = 0,301$), novamente sem significância estatística. Finalmente, o quinto segmento (final de 2023 e 2024) indicou nova tendência positiva ($\beta = 0,255$; $p = 0,002$), com alta significância estatística. Esses resultados revelam que, apesar de variações ao longo dos anos, a classe FC manteve uma

capacidade de recuperação consistente, especialmente nos períodos imediatamente posteriores às quebras estruturais.


A tendência da classe FS apresentou três segmentos distintos, separados por dois pontos de quebra detectados ao longo da série temporal. O primeiro segmento (2019-2020), indica uma leve tendência negativa ($\beta = -0,030$; $p = 0,374$), estatisticamente não significativa, indicando estabilidade na dinâmica da vegetação nesse período. No segundo segmento (2020-2022), houve uma mudança acentuada, caracterizada por uma tendência positiva significativa ($\beta = 0,253$; $p = 0,000$), sugerindo um período de recuperação expressiva da vegetação após um possível evento de distúrbio.

Por fim, no terceiro segmento (final de 2022 a 2024), a tendência se inverteu, apresentando um declínio moderado ($\beta = -0,086$; $p = 0,000$), também estatisticamente significativo, indicando uma nova fase de degradação ou perda de vigor vegetativo. Esse comportamento sugere um padrão de resiliência mais vulnerável às pressões ambientais recorrentes em comparação à FC. A resposta menos vigorosa pode estar associada às características estruturais da vegetação savânica, como maior presença de biomassa lenhosa e menor velocidade de regeneração pós-fogo (DANTAS *et al.*, 2013).

A análise da componente sazonal (St) do índice NBR (Figura 60 (c) e (d)) para as classes revela padrões semelhantes, com sazonalidade anual bem definida e estável ao longo do período analisado. Embora a amplitude da sazonalidade seja ligeiramente maior na classe FS, indicando uma resposta mais intensa às variações sazonais, não são observadas diferenças qualitativas significativas entre as classes.

Em seguida, são apresentadas as análises de tendência, sazonalidade e identificação de quebras nas séries temporais dos coeficientes de retroespalhamento SAR σ_{VH}^0 (Figura 61 (a, b)) e σ_{VV}^0 (Figura 61 (c, d)), para as classes FC e FS.

Figura 61 - Séries temporais dos coeficientes de retroespalhamento SAR σ_{VH}^0 (a, b) e σ_{VV}^0 (c, d) geradas para as classes FC e FS, bem como suas respectivas decomposições obtidas pelo algoritmo BFAST.



A análise BFAST do coeficiente de retroespalhamento SAR σ_{VH}^0 , nas formações FC (Figura 61 (a)) e FS (Figura 61 (b)), evidencia padrões distintos de impacto e recuperação, possivelmente relacionados a distúrbios como queimadas e eventos climáticos extremos, com variações expressivas nas tendências ao longo do tempo.

A decomposição da série temporal da classe FC evidenciou cinco segmentos de tendência distintos entre 2019 e 2024, separados por quatro pontos de quebra detectados pela análise BFAST. No primeiro segmento (2019-2020), foi observada uma tendência negativa ($\beta = -0,820$; $p = 0,004$), estatisticamente significativa, indicando uma possível degradação da vegetação associada a distúrbios ambientais e a queimadas de baixa severidade ou extensão, como observado na Figura 53.

No segundo segmento (2020-2021), a tendência se inverteu para positiva ($\beta = 6,550$; $p = 0,108$), porém sem significância estatística, sugerindo um início de recuperação, ainda que com alta variabilidade. No terceiro segmento (2021-2022), a

tendência positiva se manteve ($\beta = 2,818$; $p = 0,000$) e apresentou alta significância, indicando uma recuperação mais robusta da estrutura da vegetação. Durante o quarto segmento (final de 2022 até o final de 2023), a tendência continuou positiva ($\beta = 0,644$; $p = 0,866$), mas sem significância estatística, apontando para uma possível estabilização dos processos de regeneração. No último segmento (final de 2023 até 2024), foi verificado um reforço na tendência positiva ($\beta = 1,742$; $p = 0,030$), estatisticamente significativo, consolidando a trajetória de recuperação observada ao longo do período.

De maneira semelhante à FC, a classe FS também apresentou alterações expressivas nas tendências da série temporal, com três segmentos distintos identificados entre 2019 e 2024. No primeiro segmento (2019-2020), foi detectada uma tendência negativa ($\beta = -0,558$; $p = 0,015$), estatisticamente significativa, refletindo igualmente a influência de distúrbios ocorridos no período. No segundo segmento (2020-2022), a tendência se inverteu e passou a ser fortemente positiva ($\beta = 1,466$; $p = 0,000$), indicando uma recuperação mais vigorosa da vegetação em comparação à FC, dado o valor mais elevado e estatisticamente significativo de β .

Entretanto, no terceiro segmento (final de 2022, se prolongando até 2024), foi observada novamente uma inversão para tendência negativa ($\beta = -1,415$; $p = 0,000$), sugerindo um novo episódio de degradação da vegetação, de forma mais abrupta do que em FC no mesmo período. Esse comportamento corrobora com a dinâmica detectada no índice espectral óptico NBR, reforçando que FS apresenta uma capacidade de recuperação reduzida ou é mais susceptível às pressões ambientais recorrentes, em comparação à FC.

A análise dos componentes resultantes da aplicação do BFAST no coeficiente de retroespalhamento σ_{VV}^0 , nas formações FC (Figura 61 (c)) e FS (Figura 61 (d)), apresentaram comportamentos semelhantes aos resultados obtidos por VH. A decomposição da série temporal da classe FC também detectou cinco segmentos de tendência entre 2019 e 2024, separados por quatro pontos de quebra.

No primeiro segmento (2019-2020), houve uma tendência negativa ($\beta = -0,688$; $p = 0,005$), estatisticamente significativa. No segundo segmento (2020-2021), a tendência se tornou positiva ($\beta = 4,073$; $p = 0,181$), porém sem significância estatística. No terceiro segmento (2021-2022), foi mantida a tendência positiva ($\beta = 2,444$; $p = 0,000$) com alta significância. A tendência permaneceu positiva no quarto segmento (final de 2022 até o final de 2023), com $\beta = 0,585$, mas sem significância estatística ($p = 0,747$). No quinto e último segmento (final de 2023 até 2024), observou-se a continuidade da tendência

positiva ($\beta = 1,460$; $p = 0,023$), estatisticamente significativa, consolidando a trajetória de recuperação observada ao longo do período.

Da mesma forma, a classe FS apresentou um padrão comparável ao observado para VH, identificando três segmentos de tendência, separados por dois pontos de quebra. No primeiro segmento (2019-2020), foi exibida uma tendência negativa ($\beta = -0,376$; $p = 0,044$), estatisticamente significativa. No segundo segmento (2020-2022), a tendência se inverteu e passou a ser positiva ($\beta = 1,172$; $p = 0,000$). Contudo, no terceiro segmento (2022-2024), houve uma nova inversão para tendência negativa ($\beta = -0,977$; $p = 0,000$). Apesar do comportamento similar entre os resultados obtidos por VV e VH, no geral, a magnitude das tendências e os p-valores apresentados por VH, foram superiores aos observados para VV.

A componente sazonal (St) obtida pelo BFAST nas polarizações VH e VV, revela um padrão cíclico anual bem definido em ambas as classes, FC e FS. Observa-se que tanto para VH quanto para VV, a componente sazonal apresenta comportamento regular e consistente ao longo dos anos, com oscilações recorrentes que indicam a influência do ciclo climático sobre a resposta do sinal de Radar. Na classe FC, a amplitude sazonal tende a ser levemente mais pronunciada, sugerindo uma maior sensibilidade da vegetação campestre às variações sazonais de umidade e cobertura vegetal. De forma geral, a forte presença da sazonalidade em ambas as classes destaca a relevância desse componente na dinâmica temporal dos dados SAR e reforça a importância de sua consideração em análises de distúrbios ambientais e regeneração da vegetação.

De maneira geral, foi observado que as polarizações VH e VV apresentaram comportamentos semelhantes dentro de cada classe de vegetação, tanto nas formações campestres (VV-FC e VH-FC) quanto nas formações savânicas (VV-FS e VH-FS). No entanto, ao se comparar as respostas entre as duas fitofisionomias, se tornaram evidentes as diferenças nos padrões de variação temporal, refletindo a influência da estrutura da vegetação e dos regimes ecológicos distintos sobre o sinal retroespalhado.

A classe FS, em ambas as polarizações, apresentou maior variabilidade temporal nas séries observadas (Y_t). Esse comportamento pode estar associado à estrutura mais complexa da vegetação savânica, composta por estratos arbóreo-arbustivos e herbáceos, os quais respondem fortemente às variações no regime hídrico e às perturbações como o fogo (FREITAS *et al.*, 2019). Em contraste, a classe FC, dominadas por gramíneas, mostraram menor variabilidade, com séries mais homogêneas ao longo do tempo, o que está de acordo com a menor biomassa e cobertura vertical dessas áreas (GIBSON, 2010).

Com base nas análises anteriores, foi possível observar uma semelhança significativa entre o comportamento do índice espectral óptico NBR e os coeficientes de retroespalhamento SAR σ_{VH}^0 e σ_{VV}^0 ao longo do tempo. Os atributos SAR e óptico revelaram padrões convergentes na detecção dos principais eventos de queimada, especialmente em 2020. Foram apresentadas quedas marcantes nesse ano, indicando forte sensibilidade às perdas de biomassa e estrutura vegetal. As respostas dos retroespalhamentos nas polarizações VH e VV acompanharam de forma consistente a dinâmica temporal observada no NBR, sendo mais pronunciada em VH, refletindo as mesmas variações associadas aos episódios de queima e aos processos de regeneração. Essa correspondência sugere que as três variáveis podem fornecer informações complementares sobre a dinâmica da vegetação.


Adicionalmente, os três parâmetros apresentaram quatro pontos de quebra na classe FC e dois na classe FS, com tendências (inclinações β) semelhantes. Os valores de p também mostraram resultados semelhantes entre os diferentes atributos, indicando consistência nas mudanças detectadas ao longo do tempo. No entanto, o início da série temporal dos coeficientes de retroespalhamento SAR (σ_{VH}^0 e σ_{VV}^0) mostrou alta significância para ambas as classes, o que não ocorreu com o índice NBR. De modo geral, o índice NBR respondeu de forma mais imediata à regeneração, enquanto σ_{VH}^0 e σ_{VV}^0 mostraram retomadas mais lentas, refletindo sua maior relação com atributos estruturais da vegetação.

Outra observação importante a ser destacada se refere à presença de um ponto de quebra em 2023 no índice óptico NBR e em σ_{VH}^0 e σ_{VV}^0 , em ambas as classes FC e FS. Mesmo sem uma queda abrupta associada a eventos de queimada em Yt nos três atributos, a identificação desse ponto de quebra pode indicar uma mudança de tendência estrutural na série temporal.

Após dois anos consecutivos com quedas significativas (2020 e 2021), provavelmente relacionadas aos eventos de fogo, o padrão observado em Yt referente ao ano de 2023 indica uma relativa estabilização dos valores dos atributos. O mesmo padrão é observado para a classe FS no índice óptico NDVI. Essa estabilização representa uma interrupção na tendência de quebra anterior, sendo reconhecida pelo BFAST como uma nova fase do comportamento da vegetação. Assim, a ausência de distúrbios relevantes em 2023 não apenas evitou nova perda de biomassa, como também configurou uma inflexão no padrão de resposta dos atributos, o que justifica a detecção do ponto de quebra.

Na sequência das análises de tendência, sazonalidade e identificação de quebras nas séries temporais, são apresentados os resultados obtidos para os atributos polarimétricos SAR PA (Figura 62 (a, b)) e DPDD (Figura 62 (c, d)).

Figura 62 - Séries temporais dos atributos polarimétricos SAR PA (a, b) e DPDD (c, d) geradas para as classes FC e FS, bem como suas respectivas decomposições obtidas pelo algoritmo BFAST.



A análise BFAST das séries temporais dos índices polarimétricos SAR PA e DPDD para as classes FC (Figura 62 (a) e (c), respectivamente) e FS (Figura 62 (b) e (d), respectivamente), revela padrões distintos de resposta em relação às classes, porém de dinâmica similar entre os índices.

No caso de FC, antes da quebra detectada em 2020, tanto o índice PA ($\beta = -0,068$; $p = 0,168$) quanto o DPDD ($\beta = -0,097$; $p = 0,168$) apresentam uma tendência de leve declínio, embora estatisticamente não significativa. Com a quebra, observa-se um aumento abrupto e significativo em ambos os índices, com valores de $\beta = 1,244$ ($p = 0,047$) para o PA e $\beta = 1,759$ ($p = 0,047$) para o DPDD. Esses resultados indicam uma resposta forte do sinal SAR polarimétrico às alterações estruturais da vegetação, associadas às queimadas de grande magnitude ocorridas nesse período. Em seguida, é

observado um novo ponto de quebra, em ambos os índices, e então, uma leve tendência de recuperação, também não significativa, com $\beta = 0,035$ ($p = 0,114$) para o PA e $\beta = 0,049$ ($p = 0,114$) para o DPDD.

Para FS, os padrões temporais apresentam características mais variáveis e um único ponto de quebra em PA e DPDD. Ambos os índices demonstram quedas significativas antes da quebra: $\beta = -0,217$ ($p = 0,001$) para o PA e $\beta = -0,327$ ($p = 0,001$) para o DPDD. Esses resultados sugerem que FS sofreu impactos progressivos já nos meses anteriores à quebra principal de 2020. Os dois índices apresentam aumentos discretos após o ponto de quebra de 2020, com $\beta = 0,021$ ($p = 0,055$) para o PA e $\beta = 0,026$ ($p = 0,087$) para o DPDD, com evidência moderada de significância.

A decomposição obtida a partir dos índices revela que o DPDD tende a apresentar variações mais intensas, com coeficientes angulares maiores, especialmente no momento da quebra, sugerindo uma maior sensibilidade do índice às mudanças estruturais da vegetação associadas a queimadas. Quanto ao PA, embora também reflita claramente a perturbação, o índice apresenta uma resposta mais moderada, porém, com uma recuperação mais acentuada após a queda de 2020, observado no componente Y_t . Ambos os índices confirmam a existência de eventos extremos em 2020/2021, coerentes com os registros de queimada no PEEA.

Finalmente, observa-se em ambos os índices e classes que, após o distúrbio de 2020, não há indícios estatisticamente significativos de recuperação da vegetação nos anos seguintes (2022–2024), embora a tendência geral dos dois índices aponte para uma estabilização ou leve crescimento.

Os resultados obtidos por meio da aplicação do modelo de decomposição de séries temporais BFAST reforçam a importância da utilização conjunta de dados ópticos e de Radar para o monitoramento completo em ambientes naturais heterogêneos como o Pantanal. Além disso, evidenciam a contribuição dos atributos SAR na detecção e caracterização dos impactos e da recuperação de eventos extremos de degradação. Em especial, os coeficientes de retroespalhamento SAR σ_{VH}^0 e σ_{VV}^0 mostraram alto grau de correlação e dinâmicas de comportamentos semelhantes nas duas formações analisadas (FC e FS) com o índice NBR, índice espectral óptico consolidado e projetado para detectar queimadas.

Por fim, os dados SAR se mostram fundamentais em regiões tropicais, onde a alta frequência de cobertura de nuvens e os efeitos atmosféricos limitam a disponibilidade e a continuidade das imagens ópticas. Por serem independentes das condições de

iluminação e meteorológicas, os sensores SAR garantem uma observação regular e confiável, essencial para a detecção de mudanças rápidas e para o acompanhamento de processos de regeneração em diferentes fases da vegetação.

6. CONCLUSÃO E RECOMENDAÇÕES

Esta tese apresenta uma investigação sobre o potencial de atributos polarimétricos extraídos de dados SAR do sensor Sentinel-1 para o mapeamento e o monitoramento das alterações provocadas pelo fogo em diferentes classes de uso e cobertura da terra em uma UC do Pantanal Mato-Grossense. Nesse contexto, considerou-se a hipótese de que imagens adquiridas no espectro de micro-ondas permitem o monitoramento sistemático e frequente das queimadas e de seus efeitos sobre a vegetação em UC do Pantanal Mato-Grossense.

A metodologia proposta seguiu uma sequência estruturada de etapas que incluiu a comparação entre atributos SAR e índices espectrais derivados do sensor óptico Sentinel-2; a aplicação e avaliação de desempenho de algoritmos de classificação baseados em técnicas de ML e DL; e a construção de séries temporais a partir de atributos polarimétricos selecionados, abrangendo o período de 2019 a 2024. A análise das séries temporais com o algoritmo BFAST permitiu identificar pontos de ruptura associados a eventos extremos, além de evidenciar padrões de tendência, sazonalidade e dinâmicas relacionadas à regeneração da vegetação e à recorrência do fogo.

Inicialmente, foi avaliado o desempenho dos dados SAR em comparação aos dados ópticos na identificação de alterações relacionadas ao fogo, por meio da análise das diferenças entre imagens pré e pós-fogo. Foram comparados os coeficientes de retroespalhamento σ_{VH}^0 e σ_{VV}^0 com o índice espectral NBR, utilizando o algoritmo RF para a classificação das áreas impactadas. Os resultados reforçaram a sensibilidade das imagens SAR às alterações estruturais causadas pelos incêndios, mesmo em comparação com os índices ópticos tradicionalmente utilizados.

Adicionalmente, o uso da rede neural de segmentação semântica U-Net demonstrou potencial para aprimorar a acurácia no mapeamento de áreas queimadas. Para isso, foi gerada a anotação de forma semiautomática, a qual foi utilizada para treinamento da rede considerando dois conjuntos de dados: um integrando informações ópticas e SAR (NBR, σ_{VH}^0 e σ_{VV}^0), e outro contendo unicamente atributos SAR (σ_{VH}^0 , σ_{VV}^0 , e o índice polarimétrico PA). Os resultados indicaram que, mesmo na ausência de dados ópticos, o uso exclusivo de dados SAR apresentou desempenho satisfatório, evidenciando a capacidade desses atributos em detectar com precisão as áreas afetadas pelo fogo.

Também foi conduzido um experimento com o objetivo de avaliar o desempenho de diferentes algoritmos de classificação baseados em ML (RF, KNN, SVM e CART),

para a detecção e o mapeamento de áreas queimadas. A análise foi realizada utilizando a diferença entre imagens pré e pós-fogo de dados SAR, a partir dos coeficientes de retroespalhamento e de índices polarimétricos derivados (dVV, dVH, dCR, dRVI, dDPSVI, dNRPB, dDPDD e dPA). Os resultados indicaram que o algoritmo RF apresentou o melhor desempenho entre os métodos avaliados, demonstrando maior capacidade de discriminar áreas afetadas pelo fogo.

Com base no *ranking* de importância dos atributos gerado pelo RF no experimento anterior, e na análise da separabilidade entre as classes de áreas queimadas e não queimadas, foram selecionados os atributos SAR mais relevantes para compor as séries temporais. Essa seleção considerou os coeficientes de retroespalhamento σ_{VH}^0 e σ_{VV}^0 , além dos índices polarimétricos CR, RVI, DPSVI, NRPB, DPDD e PA. Destacaram-se, entre os mais relevantes, os coeficientes σ_{VH}^0 e σ_{VV}^0 , além dos índices PA e DPDD.

A análise de séries temporais dos atributos SAR selecionados, dos índices ópticos NDVI e NBR, incluindo variáveis meteorológicas (precipitação e temperatura) permitiu uma análise abrangente da dinâmica sazonal e das respostas da vegetação em distintos tipos de cobertura. A análise temporal revelou padrões sazonais consistentes e possibilitou a caracterização da dinâmica da vegetação dos diferentes tipos de uso e cobertura da terra. Os coeficientes de retroespalhamento σ_{VH}^0 e σ_{VV}^0 e os índices PA e DPDD mostraram sensibilidade às alterações estruturais da vegetação e às variações relacionadas à severidade do fogo e à regeneração da vegetação. Ressalta-se, especialmente, o σ_{VH}^0 , cuja maior sensibilidade a alterações na estrutura da vegetação o torna particularmente eficiente na detecção de impactos mais severos.

A aplicação do algoritmo BFAST nas séries temporais permitiu a identificação de pontos de ruptura associados a eventos extremos, oferecendo uma abordagem robusta para o monitoramento contínuo das dinâmicas ambientais. Observou-se, por exemplo, que áreas de vegetação campestre apresentaram maior resiliência e regeneração mais rápida, enquanto formações florestais e savânicas sofreram impactos prolongados, especialmente após os incêndios severos de 2020. Além disso, os comportamentos dos coeficientes de retroespalhamento σ_{VH}^0 e σ_{VV}^0 se mostraram muito similares ao índice óptico NBR, tradicionalmente utilizado na detecção de áreas queimadas, reforçando a eficácia dos dados SAR no monitoramento pós-fogo.

Os resultados obtidos ao longo desta pesquisa reforçam a importância e a viabilidade do uso de dados SAR no monitoramento ambiental do Pantanal,

especialmente frente às mudanças climáticas e ao aumento dos incêndios em áreas protegidas. A capacidade dos sensores SAR de adquirir informações mesmo sob cobertura de nuvens ou em condições atmosféricas adversas, os torna estratégicos para regiões como o Pantanal. A integração com dados ópticos, aliada à aplicação de algoritmos de ML e DL e à construção de séries temporais, configura abordagens robustas para a caracterização e o acompanhamento de áreas impactadas pelo fogo. Nesse contexto, a identificação dos atributos polarimétricos mais sensíveis aos efeitos do fogo e sua aplicação em séries temporais oferece suporte relevante ao monitoramento ambiental e para a detecção de distúrbios em áreas naturais.

Embora o uso do fogo faça parte da dinâmica tradicional do bioma, especialmente em práticas agropecuárias, alterações no regime hidrológico e o uso inadequado do solo têm tornado sua ocorrência cada vez mais imprevisível e grave. Em eventos extremos, como a seca de 2020, o fogo se espalha rapidamente, dificultando o controle e gerando impactos ambientais severos, cenário que evidencia a importância do monitoramento contínuo na unidade de conservação estudada. A abordagem adotada nesta pesquisa contribui para o desenvolvimento de políticas públicas voltadas à conservação da biodiversidade, à prevenção de incêndios e ao manejo sustentável dos recursos naturais. Além disso, fortalece estratégias de monitoramento de longo prazo, essenciais para a gestão adaptativa de ecossistemas altamente dinâmicos e vulneráveis como o Pantanal.

Diante desse conjunto de evidências, confirma-se a hipótese inicialmente proposta, uma vez que os dados SAR, especialmente os atributos polarimétricos analisados, demonstraram eficácia no monitoramento sistemático das queimadas e de seus impactos sobre a vegetação na UC do Pantanal Mato-Grossense estudada.

Como sugestões para trabalhos futuros, recomenda-se a inclusão de atributos texturais derivados das imagens SAR para aprimorar a classificação de áreas queimadas, visto que a resposta do sinal de Radar pode variar significativamente de acordo com a densidade da vegetação e a rugosidade superficial, características que podem ser melhor capturadas por meio de métricas texturais. No *software* SNAP, é possível extrair diversos atributos texturais por meio do módulo "*Grey Level Co-occurrence Matrix (GLCM)*", como, por exemplo: contraste, entropia, correlação e variância. Além disso, a realização de classificações específicas por tipo de uso e cobertura da terra pode melhorar a acurácia dos modelos, considerando a resposta diferenciada das formações vegetais aos distúrbios. A adoção de outras abordagens baseadas em aprendizado profundo também deve ser

explorada para identificação automática de padrões de queimada e regeneração, potencializando o uso de séries temporais para fins de monitoramento contínuo e prevenção de incêndios.

REFERÊNCIAS

- AIDA. Organizações pedem proteção ao Pantanal diante da crise por queimadas e degradação ambiental. **AIDA – Interamerican Association for Environmental Defense**, 26 ago. 2024. Disponível em: <https://aida-americas.org/es/prensa/organizacoes-pedem-protecao-ao-pantanal-diante-da-crise-por-queimadas-e-degradacao-ambiental>. Acesso em: 10 mai. 2025.
- ALENCAR, A.; Z. SHIMBO, J.; LENTI, F.; MARQUES, C. B.; ZIMBRES, B.; ROSA, M.; ARRUDA, V.; CASTRO, I.; RIBEIRO, J. P. F. M.; VARELA, V.; ALENCAR, I.; PIONTEKOWSKI, V.; RIBEIRO, V.; M. C. BUSTAMANTE, M.; SANO, E. E.; BARROSO, M. Mapping Three Decades of Changes in the Brazilian Savanna Native Vegetation Using Landsat Data Processed in the Google Earth Engine Platform. **Remote Sensing**, v. 12, n.6, p. 924, 2020. DOI: 10.3390/rs12060924
- ALENCAR, A. A. C.; ARRUDA, V. L. S.; SILVA, W.V.D.; CONCIANI, D.E.; COSTA, D.P.; CRUSCO, N.; DUVERGER, S.G.; FERREIRA, N.C.; FRANCA-ROCHA, W.; HASENACK, H.; et al. Long-Term Landsat-Based Monthly Burned Area Dataset for the Brazilian Biomes Using Deep Learning. **Remote Sensing**, v. 14, n. 11, p. 2510, 2022. DOI: 10.3390/rs14112510
- ALLEN, J.L.; SORBEL, B. Assessing the differenced Normalized Burn Ratio's ability to map burn severity in the boreal forest and tundra ecosystems of Alaska's national parks. **Int. J. Wildl. Fire**, v. 17, n. 4, p. 463–475, 2008. DOI: 10.1071/WF08034
- ANA (Agência Nacional De Águas). **Base Hidrográfica: Rios. 2012**. Disponível em: <https://metadados.snirh.gov.br/geonetwork/srv/api/records/a01764d3-4742-4f7d-b867-01bf544dde6d>. Acesso em: 10 mai. 2025.
- ANA (Agência Nacional de Águas). **Rede Hidrometeorológica Nacional – RHN**. Disponível em: <https://www.snirh.gov.br/hidroweb/mapa>. Acesso em: 10 mai. 2025.
- ANA (Agência Nacional De Águas). **Regiões Hidrográficas. 2020**. Disponível em: <https://metadados.snirh.gov.br/geonetwork/srv/api/records/0574947a-2c5b-48d2-96a4-b07c4702bbab>. Acesso em: 8 mai. 2025.
- ANA (Agência Nacional De Águas). **Diretoria Colegiada da ANA aprova Declaração de Escassez Quantitativa dos Recursos Hídricos da Região Hidrográfica do Paraguai. 2024**. Disponível em: <https://www.gov.br/ana/pt-br/assuntos/noticias-e-eventos/noticias/diretoria-colegiada-da-ana-aprova-declaracao-de-escassez-quantitativa-dos-recursos-hidricos-da-regiao-hidrografica-do-paraguai>. Acesso em: 10 mai. 2025.
- ANGELSEN. A.; KAIMAWOTIZ, D. **Agricultural Technologies and Tropical Deforestation**. Wallingford. UK: Biddles Ltd, Guildford and King's Lynn, 2001. 422 p.
- ARRUDA, R. “Populações tradicionais” e a proteção dos recursos naturais em unidades de conservação. **Ambiente e Sociedade**, v. 5, p. 79-92, 1999.
- ARRUDA, D. L.; KER, J. C.; VELOSO, G. V.; HENRIQUES, R. J.; FERNANDES-FILHO, E. I.; CAMÊLO, D. L.; GOMES, L. C.; SCHAEFER, C. E. G. R. Soil carbon

prediction in Marajó island wetlands. **Revista Brasileira de Ciência do Solo**, Viçosa, MG, v. 48, e0230162, 2024. DOI: 10.36783/18069657rbc20230162

ASHOURLOO, D.; NEMATOLLAHI, H.; HUETE, A.; AGHIGHI, H.; AZADBAKHT, M.; SHAHRABI, H. S.; GOODARZDASHTI, S. A new phenology-based method for mapping wheat and barley using time-series of Sentinel-2 images, **Remote Sensing of Environment**, v. 280, ISSN 0034-4257, p.113206, 2022. DOI: 10.1016/j.rse.2022.113206

AVETISYAN, D.; BORISOVA, D.; VELIZAROVA, E. Integrated Evaluation of Vegetation Drought Stress through Satellite Remote Sensing. **Forests**, v. 12, n. 8, p. 974, 2021. DOI: 10.3390/f12080974

BAN, Y.; ZHANG, P.; NASCETTI, A.; BEVINGTON, A. R.; WULDER, M. A. Near Real-Time Wildfire Progression Monitoring with Sentinel-1 SAR Time Series and Deep Learning. **Scientific Reports** v. 10, p. 1322, 2020. DOI: 10.1038/s41598-019-56967-x

BARONI, I. **Incêndios no MT ameaçam uma das maiores populações de onças-pintadas do mundo**. Fauna News, 2020. Disponível em: <https://faunanews.com.br/incendios-no-mt-ameacam-uma-das-maiores-populacoes-de-oncas-pintadas-do-mundo/>. Acesso em: 20 mai. 2025.

BEHMANN, J.; MAHLEIN, A. K.; RUMPF, T.; RÖMER, C.; PLÜMER, L. A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. **Precision Agriculture**, v. 16, p. 239-260, 2015.

BÓCOLI, F. A.; RIBEIRO, D.; MANCINI, M.; SOUSA, L. A.; BARBOSA, S. M.; SERAFIM, M. E.; SILVA, B. M.; AVANZI, J. C.; GUILHERME, L. R. G.; CURI, N.; SILVA, S. H. G. Can environmental variables, high sampling density and machine learning deliver detailed maps of soil organic carbon and carbon stock in tropical regions? **CATENA**, v.249, ISSN 0341-8162, p.108718, 2025. DOI: 10.1016/j.catena.2025.108718

BRASIL. **Lei nº 9.985, de 18 de julho de 2000**. Regulamenta o art. 225, § 1º, incisos I, II, III e VII da Constituição Federal, institui o Sistema Nacional de Unidades de Conservação da Natureza e dá outras providências. Diário Oficial da União: seção 1, Brasília, DF, p. 1, 19 jul. 2000. Disponível em: https://www.planalto.gov.br/ccivil_03/leis/l9985.htm. Acesso em: 20 mai. 2025.

BRAZIL DATA CUBE. **Time series analysis and machine learning**, 2020. Disponível em: <https://brazil-data-cube.github.io/worcap-2020/time-series-ml.html>. Acesso em: 20 mai. 2025.

BREIMAN, L.; FRIEDMAN, J.; OLSHEN, R.; STONE, C. **Classification and Regression Trees**. (1st ed.). Chapman and Hall/CRC, 1984. DOI: 10.1201/9781315139470

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

BRIGHT, B. C.; HUDAK, A. T.; KENNEDY, R. E. et al. Examining post-fire vegetation recovery with Landsat time series analysis in three western North American forest types. **Fire Ecology**, v. 15, n. 8, 2019. DOI: 10.1186/s42408-018-0021-9

BUSSINGUER, J. F.; BAPTISTA, G. M. M.; SANO, E. E.; LEAL, F. A. Understanding the spatio-temporal behavior of Sentinel-1 SAR vegetation indices over the Brazilian Savanna. **IEEE Transactions on Geoscience and Remote Sensing**, v. 62, n. 4405618, p. 1–18, 2024. DOI: 10.1109/TGRS.2024.3381468

CAMARGO, F. F.; SANO, E. E.; ALMEIDA, C. M.; MURA, J. C.; ALMEIDA, T. A Comparative Assessment of Machine-Learning Techniques for Land Use and Land Cover Classification of the Brazilian Tropical Savanna Using ALOS-2/PALSAR-2 Polarimetric Images. **Remote Sens.**, v. 11, n. 13, p. 1600, 2019. DOI: 10.3390/rs11131600

CAMPS-VALLS, G.; TUIA, D.; ZHU, X. X.; REICHSTEIN, M. **Deep learning for the Earth sciences: A comprehensive approach to remote sensing, climate science and geosciences**. Wiley and Sons, 2021.

CARREIRAS, J. M. B.; JONES, J.; LUCAS, R. M.; SHIMABUKURO, Y. E. Mapping major land cover types and retrieving the age of secondary forests in the Brazilian Amazon by combining single-date optical and Radar remote sensing data, **Remote Sensing of Environment**, v. 194, ISSN 0034-4257, p. 16-32, 2017 DOI: 10.1016/j.rse.2017.03.016

CARVER, K. R. **SAR Synthetic Aperture Radar - Earth Observing System**. Washington: NASA Instrument Report, p. 233, 1988.

CCRS/NRS (Canada Centre for Remote Sensing/ Natural Resources Canada). **Tutorial: Radar Remote Sensing**. 2008. Disponível em: <http://www.ccrs.nrcan.gc.ca>. Acesso em: 8 jun. 2020.

CCRS/NRS (Canada Centre for Remote Sensing/ Natural Resources Canada). **Fundamentals of Remote Sensing, a Canada Centre for Remote Sensing Tutorial**. Disponível em: https://www.nrcan.gc.ca/sites/www.nrcan.gc.ca/files/earthsciences/pdf/resource/tutor/fundam/pdf/fundamentals_e.pdf. Acesso em: 10 jan. 2025.

CHARBONNEAU, F.; TRUDEL, M.; FERNANDES, R. Use of Dual Polarization and MultiIncidence SAR for soil permeability mapping. In: **Advanced Synthetic Aperture Radar (ASAR)**, St-Hubert, Canada, 2005.

CHEN, K-S. **Principles of Synthetic Aperture Radar Imaging: A System Simulation Approach**. CRC Press, Taylor & Francis Group, 2016.

CHRISTOPOULOU, A.; MALLINIS, G.; VASSILAKIS, E.; FARANGITAKIS, G.-P.; FYLLAS, N. M.; KOKKORIS, G. D.; ARIANOUTSOU, M. Assessing the impact of different landscape features on post-fire forest recovery with multitemporal remote sensing data: the case of Mount Taygetos (southern Greece). **International Journal of Wildland Fire**, v. 28, n. 7, p. 521-532, 2019. DOI: 10.1071/WF18153

CNUC (Cadastro Nacional de Unidades de Conservação). **Painel Unidades de Conservação**. MMA - Ministério do Meio Ambiente. Disponível em: <https://cnuc.mma.gov.br/powerbi>. Acesso em: 12 mai. 2025.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35–46, 1991. DOI: 10.1016/0034-4257(91)90048-B

CORTES, C.; VAPNIK, V. **Support-Vector Networks**. **Machine Learning**, v. 20, n. 3, p. 273-297, 1995.

COVER, T. M.; HART, P. E. Nearest Neighbor Pattern Classification. **IEEE Transactions on Information Theory**, v. 13, n. 1, p. 21-27, 1967.

DALPONTE, M.; MARINELLI, D.; SOLANO-CORREA, Y.T. Effect of DEM Used for Terrain Correction on Forest Windthrow Detection Using COSMO SkyMed Data. **Remote Sensing**, v.16, n. 22, p. 4309, 2024. DOI: 10.3390/rs16224309

DANTAS, V. D. L.; HIROTA, M.; OLIVEIRA, R. S.; PAUSAS, J. G. Fire drives functional thresholds on the savanna–forest transition. **Ecology**, v. 94, n. 11, p. 2454–2463, 2013. DOI: 10.1890/12-1629.1

DELCOURT, C.J.F.; COMBEE, A.; IZBICKI, B.; MACK, M.C.; MAXIMOV, T.; PETROV, R.; ROGERS, B.M.; SCHOLTEN, R.C.; SHESTAKOVA, T.A.; VAN WEES, D.; VERAVERBEKE, S. Evaluating the Differenced Normalized Burn Ratio for Assessing Fire Severity Using Sentinel-2 Imagery in Northeast Siberian Larch Forests. **Remote Sensing**, v. 13, n. 12, p. 2311, 2021. DOI: 10.3390/rs13122311

DINIZ, J.; GAMA, F.; ADAMI, M. Evaluation of polarimetry and interferometry of Sentinel-1A SAR data for land use and land cover of the Brazilian Amazon region. **Geocarto International**, v. 37, n. 5, p. 1482-1500, 2020. DOI: 10.1080/10106049.2020.1773544

DOBSON, M.C.; ULABY, F.T.; LETOAN, T.; BEAUDOIN, A.; KASISCHKE, E.S.; CHRISTENSEN, N. Dependence of Radar backscatter on coniferous forest biomass. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 412–415, 1992.

DOS REIS, A. A.; FRANKLIN, S. E.; MELLO, J. M.; JUNIOR, F. W. A. Volume estimation in a Eucalyptus plantation using multi-source remote sensing and digital terrain data: a case study in Minas Gerais State, Brazil. **International Journal of Remote Sensing**, v. 40, n. 7, p. 2683-2702, 2019. DOI: 10.1080/01431161.2018.1530808

DUARTE, R.M.; WOZNIAK, E.; RECONDO, C.; CABO, C.; MARQUÍNEZ, J.; FERNÁNDEZ, S. Estimation of surface roughness and stone cover in burnt soils using SAR images. **Catena**, v. 74, n. 3, p. 264–272, 2008. DOI: 10.1016/j.catena.2008.05.003

ELHAG, M.; YIMAZ, N.; BAHRAWI, J.; BOTEVA, S. Evaluation of Optical Remote Sensing Data in Burned Areas Mapping of Thasos Island, Greece. **Earth Systems and Environment**, v. 4, p. 813–826, 2020. DOI: 10.1007/s41748-020-00195-1

EL HAJJ, M.; BAGHDADI, N.; ZRIBI, M.; BAZZI, H. Synergic Use of Sentinel-1 and Sentinel-2 Images for Operational Soil Moisture Mapping at High Spatial Resolution Over Agricultural Areas. **Remote Sensing**, v. 9, n. 12, p. 1292, 2017. DOI: 10.3390/rs9121292

EMBRAPA (EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA). Serviço Nacional de Levantamento e Conservação de Solos. **Súmula da 10. Reunião Técnica de Levantamento de Solos**. Rio de Janeiro: EMBRAPA-SNLCS, 1979. 83 p. (Micelânea, 1). Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/327212/1/SNLCSMiscelanea11979.pdf>. Acesso em: 20 mai. 2025.

EPTING, J.; VERBYLA, D.; SORBEL, B. Evaluation of remotely sensed indices for assessing burn severity in interior Alaska using Landsat TM and ETM+. **Remote Sens. Environ.**, v. 96, n. 3-4, p. 328–339, 2005. DOI: 10.1016/j.rse.2005.03.002

ESA (European Space Agency). **Earth Online**. 2022. Disponível em: <https://earth.esa.int/eogateway/missions/ers/Radar-courses/Radar-course-2>. Acesso em: 20 jan. 2022 (2022a).

ESA (European Spatial Agency). **Radiometric Calibration of S-1 Level-1 Products Generated by the S-1 IPF**. 2022. Disponível em: <https://sentinel.esa.int/documents/247904/685163/S1-Radiometric-Calibration-V1.0.pdf>. Acesso em: 12 fev. 2022 (2022b).

ESA (European Space Agency). **Sentinel-1**. 2025. Disponível em: https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-1. Acesso em: 14 mai. 2025 (2025a).

ESA (European Space Agency). **SentiWiki**. Disponível em: <https://sentiwiki.copernicus.eu/web/sentiwiki/>. Acesso em: 20 mar. 2025 (2025b).

EVERINGHAM, M., VAN GOOL, L., WILLIAMS, C. K. I., WINN, J., & ZISSERMAN, A. The Pascal Visual Object Classes (VOC) Challenge. **International Journal of Computer Vision**, v. 88, p. 303–338, 2010. DOI: 10.1007/s11263-009-0275-4

FERNÁNDEZ-MANSO, A.; FERNÁNDEZ-MANSO, O.; QUINTANO, C. SENTINEL-2A red-edge spectral indices suitability for discriminating burn severity. **Int. J. Appl. Earth Obs. Geoinf.**, v. 50, p. 170–175, 2016. DOI: 10.1016/j.jag.2016.03.005

FILGUEIRAS, R.; MANTOVANI, E.C.; ALTHOFF, D.; FERNANDES FILHO, E.I.; Cunha, F.F.d. Crop NDVI Monitoring Based on Sentinel 1. **Remote Sensing**, v. 11, n. 12, p. 1441, 2019. DOI: 10.3390/rs11121441

FILIPPI, A. M.; JENSEN, J. R. Fuzzy learning vector quantization for hyperspectral coastal vegetation classification. **Remote Sensing of Environment**, v. 100, n. 4, p. 512–530, 2006. DOI: 10.1016/j.rse.2005.11.007

FREITAS, D. M.; SANO, E. E.; SOUZA, R. A. Potencial das imagens multipolarizadas do satélite ALOS/PALSAR na discriminação de cobertura vegetal do bioma Pantanal: estudo de caso na região do médio Taquari, MS. **Revista Brasileira de Cartografia**, [S. l.], v. 66, n. 2, 2014. DOI: 10.14393/rbcv66n2-43907

GAO, Y.; SKUTSCH, M.; PANEQUE-GÁLVEZ, J.; GHILARDI, A. Remote sensing of forest degradation: a review. **Environmental Research - Letters**, v. 15, n. 10, p. 103001, 2020. DOI: 10.1088/1748-9326/abaad7

GAO, Y.; SOLÓRZANO, J.V.; QUEVEDO, A.; LOYA-CARRILLO, J.O. How BFAST Trend and Seasonal Model Components Affect Disturbance Detection in Tropical Dry Forest and Temperate Forest. **Remote Sensing**, v. 13, n. 11, p. 2033, 2021. DOI: 10.3390/rs13112033

GIBSON, D. J. **Grasses and Grassland Ecology**. Oxford University Press. Frits van Oudtshoorn, New York, v. 27, n. 1, p. 63-64, 2010. DOI: 10.2989/10220111003703542

GIBSON, R. K.; MITCHELL, A.; CHANG, H.-C. Image Texture Analysis Enhances Classification of Fire Extent and Severity Using Sentinel 1 and 2 Satellite Imagery. **Remote Sensing**, v. 15, n. 14, p. 3512, 2023. DOI: doi.org/10.3390/rs15143512

GLOBAL GOALS. **Goal 15: Life on Land**. 2025. Disponível em: <https://www.globalgoals.org/goals/15-life-on-land/>. Acesso em: 14 mai. 2025.

GÓMEZ, C.; WHITE, J. C.; WULDER, M. A. Optical remotely sensed time series data for land cover classification: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 116, p. 55-72, 2016. DOI: 10.1016/j.isprsjprs.2016.03.008

GONZALO-MARTÍN, C.; LILLO-SAAVEDRA, M.; GARCÍA-PEDRERO, A.; LAGOS, O.; MENASALVAS, E. Daily Evapotranspiration Mapping Using Regression Random Forest Models. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 12, p. 5359 – 5368, 2017. DOI: 10.1109/JSTARS.2017.2733958

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016.

GOVERNO FEDERAL. **Mudança do clima intensificou em 40% incêndios no Pantanal em junho, mostra estudo**. Ministério do Meio Ambiente e Mudança do Clima, 8 ago. 2024. Disponível em: <https://www.gov.br/mma/pt-br/assuntos/noticias/mudanca-do-clima-intensificou-em-40-incendios-no-pantanal-em-junho-mostra-estudo>. Acesso em: 20 mai. 2025.

HARFENMEISTER, K.; SPENGLER, D.; WELTZIEN, C. Analyzing Temporal and Spatial Characteristics of Crop Parameters Using Sentinel-1 Backscatter Data. **Remote Sensing**, v. 11, n. 13, p. 1569, 2019. DOI: 10.3390/rs11131569

HENDERSON, F.M.; LEWIS, A.J. **Manual of remote sensing: principles and applications of imaging Radar**, 3rd edition. USA: John Wiley Sons. 896 p., 1998.

HULLEY, G.; HOOK, S. **MODIS/Aqua Land Surface Temperature/3-Band Emissivity Monthly L3 Global 0.05Deg CMG V061** [Data set]. NASA EOSDIS Land Processes Distributed Active Archive Center, 2021. DOI: 10.5067/MODIS/MYD21C3.061

IBGE (Instituto Brasileiro de Geografia e Estatística). **Biomass e Sistema Costeiro-Marinho do Brasil 2024: mapa em formato shapefile**. Rio de Janeiro: IBGE, 2024a. Disponível em: <https://www.ibge.gov.br/geociencias/cartas-e-mapas/informacoes-ambientais/15842-biomass.html?=&t=downloads>. Acesso em: 15 mai. 2025.

IBGE (Instituto Brasileiro de Geografia e Estatística). **Malhas territoriais 2024: malhas digitais dos municípios brasileiros**. Rio de Janeiro: IBGE, 2024b. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/malhas-territoriais/15774-malhas.html>. Acesso em: 15 mai. 2025.

IBGE (Instituto Brasileiro de Geografia e Estatística). **Limites e principais características dos biomas brasileiros: Pantanal e Cerrado**. Rio de Janeiro: IBGE, 2019. Disponível em: https://www.ibge.gov.br/apps/biomass/pdf/Lim06_PantCerr.pdf. Acesso em: 20 mai. 2025.

ICEYE. Radiometric Considerations. **ICEYE Product Documentation**, versão 5.0. Disponível em: <https://iceye-ltd.github.io/product-documentation/5.0/productFormats/radiometric/>. Acesso em: 25 mai. 2025.

INPE (Instituto Nacional de Pesquisas Espaciais). **Banco de Dados Geográficos – Topodata: Modelo Digital de Elevação (SRTM)**. São José dos Campos: INPE, 2025. Disponível em: <http://www.dsr.inpe.br/topodata/>. Acesso em: 22 mai. 2025 (2025a).

INPE (Instituto Nacional de Pesquisas Espaciais). **TerraBrasilis – Programa Queimadas: Dados Abertos – Focos de Queimadas**. São José dos Campos: INPE, 2025. Disponível em: <https://terraBrasilis.dpi.inpe.br/queimadas/portal/dados-abertos/#dados-focos>. Acesso em: 22 mai. 2025 (2025b).

IPCC (Intergovernmental Panel on Climate Change). **Climate Change 2021: The Physical Science Basis**. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Edited by V. Masson-Delmotte et al. Cambridge: Cambridge University Press, 2021. DOI: 10.1017/9781009157896

IPCC (Intergovernmental Panel on Climate Change). **Climate Change 2023: Synthesis Report**. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Edited by H. Lee and J. Romero. Geneva, Switzerland: IPCC, p. 35-115, 2023. DOI: 10.59327/IPCC/AR6-9789291691647

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma perspectiva em recursos terrestres**. Tradução: José Carlos N. Epiphânio, et al. São José dos Campos, SP: Parêntese, 2009.

KENNEDY, R. E.; YANG, Z.; COHEN, W. B. Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr — Temporal segmentation

algorithms. **Remote Sensing of Environment**, v. 114, n. 12, p. 2897–2910, 2010. DOI: 10.1016/j.rse.2010.07.008

KEY, C. H., BENSON, N. C. **The Normalized Burn Ratio (NBR): A Landsat TM radiometric measure of burn severity**. U.S. Dep. of the Interior, Northern Rocky Mountain Sc. Centre, 1999.

KEY, C. H., BENSON, N. C. **Landscape Assessment (LA): Sampling and Analysis Methods**. USDA Forest Service General Technical Report RMRS-GTR-164-CD, 2006.

KIM, Y.; VAN ZYL, J. J. A time-series approach to estimate soil moisture using polarimetric Radar data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 8, p. 2519–2527, 2009.

KOYAMA, C. N.; WATANABE, M.; HAYASHI, M.; OGAWA, T.; SHIMADA, M. Mapping the spatiotemporal variability of tropical forests by ALOS-2 L-band SAR big data analysis. **Remote Sensing of Environment**, v. 233, 111372, 2019. DOI: 10.1016/j.rse.2019.111372

KURNIAWAN, R.; SUJONO, I.; CAESARENDRA, W. et al. Detection of flood-affected areas using multitemporal remote sensing data: a machine learning approach. **Earth Sci Inform**, v. 18, n. 35, 2025. DOI: 10.1007/s12145-024-01549-3

LAPIG (Laboratório de Processamento de Imagens e Geoprocessamento). **Chave de Interpretação Visual de Queimadas no Cerrado e Pantanal**. Disponível em: <https://chave.lapig.iesa.ufg.br/pt/>. Acesso em: 18 mai. 2025.

LARY, D. J.; ALAVI, A. H.; GANDOMI, A. H.; WALKER, A. L. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, v. 7, n. 1, p. 3-10, 2016. DOI: 10.1016/j.gsf.2015.07.003

LASAPONARA, R.; TUCCI, B. Identification of Burned Areas and Severity Using SAR Sentinel-1. **IEEE Geoscience and Remote Sensing Letters**, v. 16, n. 6, p. 917-921, 2019. DOI: 10.1109/LGRS.2018.2888641

LEE, J.; POTTIER, E. **Polarimetric Radar imaging from basics to applications**. New York: CRC Press, 2009.

LI, Q.; FU, X.; LI, H.; ZHOU, H. Advancing County-Level Potato Cultivation Area Extraction: A Novel Approach Utilizing Multi-Source Remote Sensing Imagery and the Shapley Additive Explanations–Sequential Forward Selection–Random Forest Model. **Agriculture**, v. 15, n. 1, p. 92, 2025. DOI: 10.3390/agriculture15010092

LIBONATI, R.; DACAMARA, C. C.; PERES, L. F.; SANDER DE CARVALHO, L. A.; GARCIA, L. C. Rescue Brazil's burning Pantanal wetlands. **Nature**, v. 588, n. 7837, p. 217-219, 2020. DOI: 10.1038/d41586-020-03464-1

LILLESAND, T.M.; KIEFER, R.W.; CHIPMAN, J.W. **Remote Sensing and Image Interpretation**. Hoboken: John Wiley & Sons Inc., 7th ed., 2015.

LINDGREN, D. T. **Land use planning and remote sensing**. Managing editor: V. Klemas, University of Delaware, DE. ISBN 90-247-3083-X, 1985.

LOPEZ-SANCHEZ, J. M. **Recent advances in Applications of SAR Polarimetry. Agriculture: Phenology retrieval**. In: 2nd Advanced Course on Radar Polarimetry Frascati, January 25, 2012.

LUSCH, D. P. **Introduction to Microwave Remote Sensing**. Basic Science Remote Sensing Initiative. Department of Geography. Michigan State University. BSRSI, 1999.

MapBiomas Fogo – Col. 3. **Projeto MapBiomas - Mapeamento das áreas queimadas no Brasil entre 1985 a 2023 - Coleção 3**. Histórico do fogo no Brasil (1985 a 2023). Disponível: <https://plataforma.brasil.mapbiomas.org/hotsite-fogo>. Acesso em: 20 mai. 2025.

MARRA, A. B.; GALO, M. L. B. T.; GIULIO TONOLO, F.; SANO, E. E.; ORLANDO, V. S. W. Burnt areas semantic segmentation from Sentinel data using the U-Net network trained with semi-automated annotations. In: **ISPRS Geospatial Week 2023**, 2023, Cairo, Egito. **Anais [...]**, v. XLVIII-1/W2-2023, p. 1459–1465, 2023. DOI: 10.5194/isprs-archives-XLVIII-1-W2-2023-1459-2023

MARRA, A.B.; GALO, M. L. B. T.; SANO, E. E. Contribution of SAR/Sentinel-1 images in the detection of burnt areas in the natural vegetation of the Brazilian Pantanal biome. **Bulletin of Geodetic Sciences**, Curitiba, v. 30, e2024005, 2024. DOI: 10.1590/s1982-21702024000100005

MASTRO, P.; MASIELLO, G.; SERIO, C.; PEPE, A., 2022. Change Detection Techniques with Synthetic Aperture Radar Images: Experiments with Random Forests and Sentinel-1 Observations. **Remote Sensing**, v. 14, n. 14, p. 3323, 2022. DOI: doi.org/10.3390/rs14143323

MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **Int. J. Remote Sens.**, v. 17, n. 7, p. 1425-1432, 1996. DOI: 10.1080/01431169608948714

MENEGASSI, Duda. **Mais de 80% da área do Parque Estadual Encontro das Águas já foi atingida pelo fogo**. O Eco, 2020. Disponível em: <https://oeco.org.br/reportagens/mais-de-80-da-area-do-parque-estadual-encontro-das-aguas-ja-foi-atingida-pelo-fogo/>. Acesso em: 5 mai. 2025.

MENESES, P. R.; ALMEIDA, T. **Introdução ao processamento de imagens de Sensoriamento Remoto**. Universidade de Brasília – UNB. Brasília. 2012.

MILLER, J.D.; THODE, A.E. Quantifying burn severity in a heterogeneous landscape with a relative version of the delta Normalized Burn Ratio (dNBR). **Remote Sens. Environ.**, v. 109, n. 1, p. 66–80, 2007. DOI: 10.1016/j.rse.2006.12.006

MODIS (MODerate Resolution Imaging Spectroradiometer). **MODIS**. Disponível em: <https://modis.gsfc.nasa.gov>. Acesso em: abril de 2025.

MORAES, E. C. **Capítulo 1 - Fundamentos de Sensoriamento Remoto**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais - INPE-8984-PUD/62, 2002.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 4ª Edição atualizada e ampliada – Viçosa, MG: Ed. UFV, 2012.

NAGAI, S.; KOBAYASHI, H.; SUZUKI, R. Remote Sensing of vegetation. In: Ohta, T. et al. (ed.). **Water-carbon dynamics in Eastern Siberia**. Ecological Studies (Analysis and Synthesis), v. 236, p. 231-252. Springer, Singapore, 2019. DOI: 10.1007/978-981-13-6317-7_10

NASA EARTH OBSERVATORY. **Fires Char the Pantanal**. 2020. Disponível em: <https://earthobservatory.nasa.gov/images/147269/fires-char-the-pantanal>. Acesso em: 1 mai. 2025.

NASIRZADEHDIZAJI, R.; SANLI, F. B.; ABDIKAN, S.; CAKIR, Z.; SEKERTEKIN, A.; USTUNER, M. Sensitivity Analysis of Multi-Temporal Sentinel-1 SAR Parameters to Crop Height and Canopy Coverage. **Applied Sciences**, v. 9, n. 4, p. 655, 2019. DOI: 10.3390/app9040655

NOVO, E. M. L. M. **Sensoriamento Remoto: princípios e aplicações**. 4ª Edição. São Paulo: Blucher, 2010.

NOLÈ, A.; RITA, A.; SPATOLA, M. F.; BORGHETTI, M. Biogeographic variability in wildfire severity and post-fire vegetation recovery across the European forests via remote sensing-derived spectral metrics, **Science of The Total Environment**, v. 823, 153807, ISSN 0048-9697, 2022. DOI: 10.1016/j.scitotenv.2022.153807

OLIVEIRA, M. T.; DAMASCENO-JUNIOR, G. A.; POTT, A., FILHO, A. C. P.; SUAREZ, Y. R., PAROLIN, P. Regeneration of riparian forests of the Brazilian Pantanal under flood and fire influence, **Forest Ecology and Management**, v. 331, p. 256-263, ISSN 0378-1127, 2014. DOI: 10.1016/j.foreco.2014.08.011

PATEL, P.; SRIVASTAVA, H.S.; PANIGRAHY, S.; PARIHAR, J.S. Comparative evaluation of the sensitivity of multi-polarized multi-frequency SAR backscatter to plant density. **Int. J. Remote Sensing**, v. 27, n. 2, p. 293–305, 2006. DOI: 10.1080/01431160500214050

PEARSON, K. Notes on Regression and Inheritance in the Case of Two Parents. **Proceedings of the Royal Society of London**, v. 58, p. 240-242, 1895. DOI: <https://doi.org/10.1098/rspl.1895.0041>

PEREIRA, L. O.; FURTADO, L. F. A.; NOVO, E. M. L. M.; SANT'ANNA, S. J. S.; LIESENBERG, V.; SILVA, T. S. F. Multifrequency and Full-Polarimetric SAR Assessment for Estimating Above Ground Biomass and Leaf Area Index in the Amazon Várzea Wetlands. **Remote Sensing**, v. 10, n. 9, p. 1355, 2018. DOI: 10.3390/rs10091355

PÉREZ-CABELLO, F.; ECHEVERRÍA, M.; IBARRA, P.; RIVA, J. Effects of Fire on Vegetation, Soil and Hydrogeomorphological Behavior in Mediterranean Ecosystems. In:

CHUVIECO, E. (ed.). **Earth Observation of Wildland Fires in Mediterranean Ecosystems**. Springer: Berlin/Heidelberg, Germany, p. 111–128, 2009.

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, ISSN 0034-4257, 2018. DOI: 10.1016/j.rse.2018.09.003

PERSELLO, C.; WEGNER, J. D.; HAENSCH, R.; TUIA, D.; GHAMISI, P.; KOEVA, M.; CAMPS-VALLS, G. Deep learning and earth observation to support the sustainable development goals: Current approaches, open challenges, and future opportunities. **IEEE Geoscience and Remote Sensing Magazine**, v. 10, n. 2, p. 172–200, 2022. DOI: 10.1109/MGRS.2021.3136100

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento Remoto da Vegetação**. 2ª Edição. Atualizada e Ampliada. São Paulo: Oficina de Textos, 2012.

POPE, K. O.; BENAYAS-REY, J. M.; PARIS, J. F. Radar remote sensing of forest and wetland ecosystems in the Central American tropics. **Remote Sensing of Environment**, v. 48, n. 2, p. 205–219, 1994.

POWERS, D. M. W. **Evaluation: From Precision, Recall and F-Factor to ROC, Informedness, Markedness and Correlation**. Mach. Learn. Technol, 2, 2008.

Projeto MapBiomas - Coleção Beta. **MapBiomas Coleção Beta de Mapas Anuais de Cobertura e Uso da Terra do Brasil com 10 metros de resolução espacial**. Disponível em: <https://brasil.mapbiomas.org/mapbiomas-cobertura-10m/>. Acesso em: 22 jan. 2025.

Projeto MapBiomas (Mapeamento Anual de Cobertura e Uso da Terra no Brasil - Coleção 9), 2024. **Destaques do Mapeamento Anual de Cobertura e Uso da Terra bioma Pantanal: Coleção 9 - 1985 a 2023**. Disponível em: https://brasil.mapbiomas.org/wp-content/uploads/sites/4/2024/12/Factsheet-Pantanal_C9_25.10_v6-1.pdf. Acesso em: 15 mai. 2025.

Projeto MapBiomas - Monitor do Fogo. **Dados Monitor Mensal do Fogo**. Disponível em: <https://brasil.mapbiomas.org/dados-monitor-mensal-do-fogo/>. Acesso em: 14 jan. 2025.

QU, L.; CHEN, Z.; LI, M. CART-RF Classification with Multifilter for Monitoring Land Use Changes Based on MODIS Time-Series Data: A Case Study from Jiangsu Province, China. **Sustainability**, MDPI, v. 11, n. 20, p. 5657, 2019. DOI: 10.3390/su11205657

QUOC, T. T. P.; LINH, T. T.; MINH, T. N. T. Comparing U-Net Convolutional Network with Mask R-CNN in Agricultural Area Segmentation on Satellite Images. In: **2020 7th NAFOSTED Conference on Information and Computer Science (NICS)**, Ho Chi Minh City, Vietnam, p. 124–129, 2020. DOI: 10.1109/NICS51282.2020.9335856

R DEVELOPMENT CORE TEAM. **R: A language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2025. Disponível em: <https://www.R-project.org/>. Acesso em: 19 abr. 2025.

RAHMAN, M. M.; MORAN, M. S.; THOMA, D. P.; BRYANT, R.; COLLINS, C. D. H.; JACKSON, T.; ORR, B. J.; TISCHLER, M. Mapping surface roughness and soil moisture using multi-angle radar imagery without ancillary data. **Remote Sens. Environ.**, v. 112, n. 2, p. 391–402, 2008. DOI: 10.1016/j.rse.2006.10.026

RANDERSON, J. T.; CHEN, Y.; VAN DER WERF, G. R.; ROGERS, B.M.; MORTON, D. C. Global burned area and biomass burning emissions from small fires. **Journal of Geophysical Research: Biogeosciences**, v. 117, n. G4, 2012. DOI: 10.1029/2012JG002128

RODRIGUES, T.; TAKAHASHI, F.; DIAS, A.; LIMA, T.; ALCÂNTARA, E. Machine learning-based Cerrado land cover classification using PlanetScope imagery. **Remote Sensing**, Basel, v. 17, n. 3, p. 480, 2025. DOI: 10.3390/rs17030480

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) **Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015**. MICCAI 2015. Lecture Notes in Computer Science. Springer, Cham., v. 9351, p. 234-241. 2015. DOI: 10.1007/978-3-319-24574-4_28

ROOHI, M.; GHAFOURI, H. R.; ASHRAFI, S. M. Advancing flood disaster management: leveraging deep learning and remote sensing technologies. **Acta Geophys.**, v.73, p. 557–575, 2025. DOI: 10.1007/s11600-024-01481-6

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In: **Third ERTS-1 Symposium**, NASA SP-351, Washington DC, 309-317, 1974.

SAATCHI, S.S.; HARRIS, N.L.; BROWN S.; LEFSKY, M.; MITCHARD, E. T. A.; SALAS, W.; ZUTTA, B. R.; BUERMANN, W.; LEWIS, S.L.; HAGEN, S.; PETROVA, S.; WHITE, L.; SILMAN, M.; MOREL, A. Benchmark map of forest carbon stocks in tropical regions across three continents. **Proceedings of the National Academy of Sciences**, v. 108, n. 24, p. 9899-9904, 2011. DOI: 10.1073/pnas.1019576108

SANO, E. E.; FERREIRA, L. G.; HUETE, A. R. Synthetic aperture Radar (L-band) and optical vegetation indices for discriminating the Brazilian savanna physiognomies: a comparative analysis. **Earth Interactions**, v. 9, p. 1-15, 2005. DOI: 10.1175/EI117.1

SANTOS, S. A.; SORIANO, B. M. A.; CARDOSO, E. L.; TOMÁS, W. M.; CRISPIM, S. M. A.; PELLEGRIN, L. A. **Uso do fogo para o manejo da vegetação no Pantanal**. Corumbá: Embrapa Pantanal, 2020. 18 p. (Documentos / Embrapa Pantanal, ISSN 1517-1990; 164). Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1123857/1/Uso-fogo-manejo-2020.pdf>. Acesso em: 10 abr. 2025.

SANTOS, E. P.; SILVA, D. D.; HUMMEL, C. A. Vegetation cover monitoring in tropical regions using SAR-C dual-polarization index: seasonal and spatial influences. **International Journal of Remote Sensing**, v. 42, n. 19, p. 7581-7609, 2021. DOI: 10.1080/01431161.2021.1959955

SANTOS, F.C.; VIEIRA, R.M. D. P.; BARBOSA, A.A; FERREIRA, Y. C.; POLIZEL, S. P.; SESTINI, M. F.; OMETTO, J. P. H. B. Application of remote sensing to analyze the loss of natural vegetation in the Jalapão Mosaic (Brazil) before and after the creation of protected area (1970–2018). **Environmental Monitoring and Assessment**, v. 194, n. 201, 2022. DOI: 10.1007/s10661-021-09651-5

SMALL, D. Flattening Gamma: Radiometric Terrain Correction for SAR Imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 8, pp. 3081-3093, 2011. DOI: 10.1109/TGRS.2011.2120616

SEEG (Sistema de Estimativa de Emissões e Remoções de Gases de Efeito Estufa). **Observatório do Clima**. Emissões Totais. Disponível em: <https://seeg.eco.br/>. Acesso em: 21 abr. 2025.

SEFAZ (Secretaria de Estado de Fazenda). Governo de Mato Grosso. **Estado cria a maior unidade de conservação do Pantanal**. Cuiabá: SEFAZ-MT, 28 dez. 2004. Disponível em: <https://www5.sefaz.mt.gov.br/-/estado-cria-a-maior-unidade-de-conservacao-do-pantanal>. Acesso em: 6 abr. 2025.

SENTINEL Collections. **Sentinel Collections**. Disponível em: <https://developers.google.com/earth-engine/datasets/catalog/sentinel?hl=pt-br>. Acesso em: 22 mar. 2025.

SEWADA, R.; GOYAL, H. Land use land cover Change Detection Using Geospatial Semantic Segmentation U-Net-ResNet Architecture. In: **IEEE 11th Region 10 Humanitarian Technology Conference (R10-HTC)**, Rajkot, India, p. 620-625, 2023. DOI: 10.1109/R10-HTC57504.2023.10461857

SCHROEDER, W.; OLIVA, P.; GIGLIO, L.; QUAYLE, B.; LORENZ, E.; MORELLI, F. Active fire detection using Landsat-8/OLI data. **Remote Sens. Environ.**, v. 185, p. 210–220, 2016. DOI: 10.1016/j.rse.2015.08.032

SHULTS, R., FARAHAT, A., USMAN, M., RAHMAN, M. M. Multi-Temporal Remote Sensing Satellite Data Analysis for the 2023 Devastating Flood in Derna, Northern Libya. **Remote Sensing**, v. 17, n. 4, p. 616, 2025. DOI: 10.3390/rs17040616

SILVA, L. G. **Comportamento e efeito do fogo sobre os ecossistemas do bioma Cerrado: modelos baseados em processos**. 2018. Tese (Doutorado em Ecologia) - Instituto De Ciências Biológicas, Universidade de Brasília, Brasília-DF, 2018.

SIVASANKAR, T.; KUMAR, D.; SRIVASTAVA, H. S.; PATEL, P. Advances in Radar Remote Sensing of Agricultural Crops: A Review. **International Journal on Advanced Science Engineering Information Technology**, v. 8, n. 4, ISSN: 2088-5334, 2018. DOI: 10.18517/ijaseit.8.4.5797

SZPAKOWSKI, D. M.; JENSEN, J. L. R. A Review of the Applications of Remote Sensing in Fire Ecology. **Remote Sensing**, v. 11, n. 22, p. 2638, 2019. DOI: 10.3390/rs11222638

TARIQ, A.; SHU, H.; LI, Q.; ALTAN, O.; KHAN, M.R.; BAQA, M.F.; LU, L. Quantitative Analysis of Forest Fires in Southeastern Australia Using SAR Data. **Remote Sensing**, v. 13, n. 12, p. 2386, 2021. DOI: 10.3390/rs13122386

THE GUARDIAN. **Brazil's Pantanal wetlands on fire – in pictures**. The Guardian, 17 set. 2020. Disponível em: <https://www.theguardian.com/environment/gallery/2020/sep/17/brazil-pantanal-wetlands-on-fire-in-pictures>. Acesso em: 15 maio 2025.

TREVETT, J. W. **Imaging Radar Resources Surveys**. London: Chapman and Hall, 1986.

TSYGANSKAYA, V.; MARTINIS, S.; MARZAHN, P.; LUDWIG, R. Detection of Temporary Flooded Vegetation Using Sentinel-1 Time Series Data. **Remote Sensing**, v. 10, n. 8, p. 1286, 2018. DOI: 10.3390/rs10081286

UNESCO. **Pantanal**. Disponível em: <https://whc.unesco.org/en/list/999/>. Acesso em: 8 maio 2025.

VAN ROSSUM, Guido. **Python Tutorial**. Release 3.7.0. 2018. Disponível em: https://bugs.python.org/file47781/Tutorial_EDIT.pdf. Acesso em: 9 abril 2025.

VERAVERBEKE, S.; GITAS, I.; KATAGIS, T.; POLYCHRONAKI, A.; SOMERS, B.; GOOSSENS, R. Assessing post-fire vegetation recovery using red–near infrared vegetation indices: Accounting for background and vegetation variability. **ISPRS J. Photogramm. Remote Sens.**, v. 68, p. 28–39, 2012. DOI: 10.1016/j.isprsjprs.2011.12.007

VERBESSELT, J.; HYNDMAN, R.; NEWNHAM, G.; CULVENOR, D. Detecting trend and seasonal changes in satellite image time series. **Remote Sensing of Environment**, v. 114, n. 1, p. 106–115, 2010. DOI: 10.1016/j.rse.2009.08.014

VREUGDENHIL, M.; WAGNER, W.; BAUER-MARSCHALLINGER, B.; PFEIL, I.; TEUBNE, I.; RÜDIGER, C.; STRAUSS, P. Sensitivity of Sentinel-1 Backscatter to Vegetation Dynamics: An Austrian Case Study. **Remote Sensing**, v. 10, n. 9, p. 1396, 2018. DOI: 10.3390/rs10091396

WAGTENDONK, J. W. V.; ROOT, R. R. The use of multi-temporal Landsat Normalized Difference Vegetation Index (NDVI) data for mapping fuel models in Yosemite National Park, USA. **Int. J. Remote Sens.**, v. 24, n. 8, p. 1639–1651, 2003. DOI: 10.1080/01431160210144679

WASSER, L.; CATTAU, M. **Lesson 4: Work with the Difference Normalized Burn Index - Using Spectral Remote Sensing to Understand the Impacts of Fire on the Landscape**, 2020. Disponível em: <https://www.earthdatascience.org/courses/earth-analytics/multispectral-remote-sensing-modis/normalized-burn-index-dNBR/>. Acesso em: 20 mar. 2025.

WATTS, L. M.; LAFFAN, S. W. Sensitivity of the BFAST algorithm to MODIS satellite and vegetation index. In: **Proceedings of the 20th International Congress on Modelling and Simulation (MODSIM2013)**, Adelaide, Australia, 2013.

WHYTE, A.; FERENTINOS, K. P.; PETROPOULOS, G. P. A new synergistic approach for monitoring wetlands using Sentinels -1 and 2 data with object-based machine learning algorithms. **Environmental Modelling & Software**, v. 104, p. 40-54, 2018. DOI: 10.1016/j.envsoft.2018.01.023

WOODHOUSE, I. H. **Introduction to Microwave Remote Sensing**. Taylor Francis: Boca Raton, FL, USA, 379 p., 2006.

WWF-Brasil (World Wildlife Fund - Brasil). **Bacia do Alto Paraguai – Resumo Executivo**. Brasília: WWF-Brasil, 2009. Disponível em: https://wwfbr.awsassets.panda.org/downloads/baciaaltoparaguai_resumoexecutivo.pdf. Acesso em: 28 abr. 2025.

WWF-Brasil (World Wildlife Fund - Brasil). **Retrospectiva 2020: Pantanal teve recordes históricos de queimadas**. Brasília: WWF-Brasil, 2020. Disponível em: <https://www.wwf.org.br/?77589/Retrospectiva-2020-Pantanal-teve-recordes-historicos-de-queimadas>. Acesso em: 28 abr. 2025.

WWF-Brasil (World Wildlife Fund - Brasil). **Pantanal**. Disponível em: <https://www.wwf.org.br/nossosconteudos/biomas/pantanal/#:~:text=O%20Pantanal%20ocupa%20uma%20%C3%A1rea,sua%20forma%C3%A7%C3%A3o%2C%20%C3%A9%20muito%20maior>. Acesso em: 30 abr. 2025.

XI, Y.; REN, C.; TIAN, Q.; REN, Y.; DONG, X.; ZHANG, Z. Exploitation of Time Series Sentinel-2 Data and Different Machine Learning Algorithms for Detailed Tree Species Classification. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 14, p. 7589-7603, 2021, DOI: 10.1109/JSTARS.2021.3098817

YAN, X.; LI, J.; SMITH, A. R.; YANG, D.; MA, T.; SU, Y.; SHAO, J. Evaluation of machine learning methods and multi-source remote sensing data combinations to construct forest above-ground biomass models. **International Journal of Digital Earth**, v. 16, n. 2, p. 4471–4491, 2023. DOI: 10.1080/17538947.2023.2270459

YANG, R-M.; GUO, W-W. Using time-series Sentinel-1 data for soil prediction on invaded coastal wetlands. **Environmental Monitoring and Assessment**, v. 191, n. 7, p. 462, 2019. DOI: 10.1007/s10661-019-7580-3

YU, B.; CHEN, F.; LI, B.; WANG, L.; WU, M. Fire Risk Prediction Using Remote Sensed Products: A Case of Cambodia. **Photogramm. Eng. Remote Sens.**, v. 83, n. 1, p. 19–25 (7), 2017. DOI: 10.14358/PERS.83.1.19

ZAFAR, Z.; ZUBAIR, M.; ZHA, Y.; FAHD S.; NADEEM, A. A Performance assessment of machine learning algorithms for mapping of land use/land cover using remote sensing data. **The Egyptian Journal of Remote Sensing and Space Sciences**, v. 27, n. 2, p. 216-226, ISSN 1110-9823, 2024. DOI: 10.1016/j.ejrs.2024.03.003

ZEILEIS, A.; GROTHENDIECK, G. Zoo: S3 Infrastructure for Regular and Irregular Time Series. **Journal of Statistical Software**, v. 14, n. 6, p. 1–27, 2005. DOI: 10.18637/jss.v014.i06

ZHANG, C.; SARGENT, I.; PAN, X.; LI, H.; GARDINER, A.; HARE, J.; ATKINSON, P. M. Joint Deep Learning for land cover and land use classification. **Remote Sensing of Environment**, v.221, p.173-187. ISSN 0034-4257, 2019. DOI: 10.1016/j.rse.2018.11.014

ZHOU, Z.; LIU, L.; JIANG, L.; FENG, W.; SAMSONOV, S.V. Using Long-Term SAR Backscatter Data to Monitor Post-Fire Vegetation Recovery in Tundra Environment. **Remote Sensing**, v. 11, n. 19, p. 2230, 2019. DOI: 10.3390/rs11192230

ZHU, X. X., TUIA, D., MOU, L., XIA, G.-S., ZHANG, L., XU, F., FRAUNDORFER, F. Deep learning in remote sensing: A comprehensive review and list of resources. **IEEE Geoscience and Remote Sensing Magazine**, v. 5, n. 4, p. 8-36, 2017. DOI:10.1109/MGRS.2017.2762307

DADOS CURRICULARES

IDENTIFICAÇÃO	
	01/02/1990
Nacionalidade	Brasileira
Nome em citações bibliográficas	Marra, Aline Barroca Marra, A. B.
Currículo Lattes	http://lattes.cnpq.br/5335757599203821
ORCID	https://orcid.org/0000-0001-7311-7312
FORMAÇÃO ACADÊMICA	
2008 - 2011	Graduação em Análise e Desenvolvimento de Sistemas Fatec Indústria de Nutrição e Saúde Animal, FATEC, Presidente Prudente
2013 - 2017	Graduação em Engenharia Cartográfica Universidade Estadual Paulista Júlio de Mesquita Filho Faculdade de Ciências e Tecnologia – Campus de Presidente Prudente
2018 - 2020	Mestrado em Ciências Cartográficas Universidade Estadual Paulista Júlio de Mesquita Filho Faculdade de Ciências e Tecnologia – Campus de Presidente Prudente
2020 - 2025	Doutorado em Ciências Cartográficas Universidade Estadual Paulista Júlio de Mesquita Filho Faculdade de Ciências e Tecnologia – Campus de Presidente Prudente
PRODUÇÃO BIBLIOGRÁFICA	
MARRA, A. B.; Galo, M. L. B. T. Detecção de áreas queimadas a partir de imagens SAR/SENTINEL-1. In: XII Colóquio Brasileiro De Ciências Geodésicas V Simpósio Brasileiro De Geomática, 2022, Curitiba-PR. XII Colóquio Brasileiro De Ciências Geodésicas V Simpósio Brasileiro De Geomática.	
MARRA, A. B.; GALO, M. L. B. T.; SANO, E. E. CONTRIBUTION OF SAR/SENTINEL-1 IMAGES IN THE DETECTION OF BURNT AREAS IN THE NATURAL VEGETATION OF THE BRAZILIAN PANTANAL BIOME. Boletim de Ciências Geodésicas, v. 30, p. e2024005, 2023.	
MARRA, A. B.; Galo, M. L. B. T.; GIULIO TONOLO, F.; SANO, E. E.; ORLANDO, V. S. W. BURNT AREAS SEMANTIC SEGMENTATION FROM SENTINEL DATA USING THE U-NET NETWORK TRAINED WITH SEMI-AUTOMATED ANNOTATIONS. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, v. XLVIII-1/W2-2023, p. 1459-1465, 2023.	
ORLANDO, V. S. W; MARTINS, G. D.; FRAGA JÚNIOR, E. F.; MARRA, A. B.; PEREIRA, F. V.; GALO, M. D. L. B. T. POTENTIAL OF MULTISPECTRAL IMAGES TAKEN BY SENSORS EMBEDDED IN UAVS FOR MONITORING THE COFFEE CROP IRRIGATION. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, v. X-1/W1-2023, p. 91-96, 2023.	

NASCIMENTO, E. S.; FERREIRA, A. A. L.; MARRA, A. B.; PINTO, M. R. E.; VAGULA, D.; SILVA, E. A.; Galo, M. L. B. T. Detecção de queimadas e análise do impacto do fogo na vegetação natural do Parque Estadual Encontro das Águas, Pantanal Matogrossense. In: XX Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2023, Florianópolis, SC. Anais do XX Simpósio Brasileiro de Sensoriamento Remoto, 2023. v. 20.
LEMES NETO, N.; MARRA, A. B.; WATANABE, F. S. Y.; Galo, M. L. B. T. Análise do potencial dos atributos polarimétricos e interferométricos SAR na detecção de áreas de mineração em terras indígenas na Amazônia. In: XIII Colóquio Brasileiro de Ciências Geodésicas (CBCG), 2024, Curitiba/PR. XIII Colóquio Brasileiro de Ciências Geodésicas (CBCG), 2024.
PARTICIPAÇÃO EM BANCAS E ORIENTAÇÕES
Bancas de trabalhos de conclusão de curso de graduação
MARRA, A. B.; TOMMASELLI, A. M. G.; CAMARGO, P. O. Participação em banca de Saito, A. T.; Ferreira, N. B.; Costa, R. F. Mapeamento de parte da área urbana de Presidente Prudente na escala 1:1.000, com GSD de 8,7 cm: Folha SF-22-Y-B-III-1-NO-F-III-6-D. 2021. Trabalho de Conclusão de Curso (Graduação em Engenharia Cartográfica) - Universidade Estadual Paulista Júlio de Mesquita Filho.
Orientações
Eduardo Nasc., Allan Ferreira, Max Pinto e Daiana Vágula. Detecção de queimadas e análise do impacto do fogo na vegetação natural do Parque Estadual Encontro das Águas, Pantanal Mato-grossense. (Coorientação). 2022. Trabalho de Conclusão de Curso. (Graduação em Engenharia Cartográfica) - Universidade Estadual Paulista Júlio de Mesquita Filho. Orientador: Aline Barroca Marra.
PARTICIPAÇÃO EM EVENTOS CIENTÍFICOS
ISPRS Geospatial Week, 2023, (Cairo, Egito). Burnt areas semantic segmentation from Sentinel data using the U-NET network trained with semi-automated annotations. 2023. (Congresso).
XII Colóquio Brasileiro De Ciências Geodésicas V Simpósio Brasileiro De Geomática, 2022, (Curitiba/PR). Detecção de áreas queimadas a partir de imagens SAR/SENTINEL-1. 2022. (Congresso).