



Classificação Supervisionada de Áreas Queimadas do Cerrado Utilizando Atributos Espectrais Provenientes de Séries Temporais do Sensor WFI

Supervised Classification of Burned Areas in the Cerrado using Spectral Attributes from Time Series based on the WFI Sensor

Alisson Cleiton de Oliveira ¹, Brenda Oliveira Rocha ², Cesar Augusto de Moraes Costa ³ e Thales Sehn Körting ⁴

1 Instituto Nacional de Pesquisas Espaciais, São José dos Campos – SP, Brasil, alisson.oliveira@inpe.br

ORCID: <https://orcid.org/0000-0001-5177-3730>

2 Instituto Nacional de Pesquisas Espaciais, São José dos Campos – SP, Brasil, brenda.rocha@inpe.br

ORCID: <https://orcid.org/0000-0002-8286-4085>

3 Instituto Nacional de Pesquisas Espaciais, São José dos Campos – SP, Brasil, cesar.moraes@inpe.br

ORCID: <https://orcid.org/0000-0002-3826-236X>

4 Instituto Nacional de Pesquisas Espaciais, São José dos Campos – SP, Brasil, thales.korting@inpe.br

ORCID: <https://orcid.org/0000-0002-0876-0501>

Recebido: 01.2024 | Aceito: 09.2024

Resumo: O Cerrado evoluiu sob a presença natural do fogo, contudo, incêndios de origem antrópica colocam em risco a conservação dos ecossistemas desse bioma, pois são mais intensos, difusos e frequentes. O monitoramento de eventos relacionados ao fogo é fundamental enquanto um instrumento de gestão ambiental. Considerando tecnologias e aplicações de sensoriamento remoto, destacam-se dois produtos principais de estudos do fogo: focos de calor (ou fogo ativo) e áreas queimadas. O objetivo deste artigo é analisar a viabilidade da utilização de séries temporais de imagens do sensor WFI (*Wide Field Imaging Camera*), que imageia nas bandas do visível e do infravermelho próximo, a bordo dos satélites CBERS-4, CBERS-4A e AMAZONIA-1, no mapeamento de áreas queimadas dos anos de 2020, 2021 e 2022 do Parque Nacional da Chapada dos Veadeiros, utilizando o *Random Forest*, algoritmo de classificação supervisionada. A série temporal é composta por 235 imagens que foram integradas em uma grade regular, resultando em seis conjuntos de dados independentes (banda do NIR e os índices espectrais BAI, EVI, GEMI, NDVI e NDWI) para treinamento, validação e teste. De forma geral, o NDVI apresentou as menores acurácias, e entre os *datasets* anuais, 2021 teve o melhor desempenho, seguido por 2020. Generalizações, conduzidas em *datasets* anuais aplicando-se os modelos multitemporais, isto é, treinados com amostras dos três anos, retornaram IoUs superiores a 70% em 2020 (exceto o EVI e o NDVI) e 2021 (exceto o NDVI) e superiores a 60% em 2022 (exceto o NDVI).

Palavras-chave: Fogo. Sensoriamento Remoto. CBERS-4. CBERS-4A. AMAZONIA-1.

Abstract: The Brazilian Cerrado evolved under natural presence of fires, but human-driven wildfires threaten the conservation of the ecosystems of this biome, as they are more intense, diffuse, and frequent. Consequently, the monitoring of fire events is an important instrument for environmental management. *Exist* two main approaches of wildfire studies considering remote sensing technologies and applications: the detection of fire foci (or active fires) and the mapping of burned areas. The objective of this article is to analyze the feasibility of using imagery time series from the WFI (*Wide Field Imaging Camera*) sensor on board the CBERS-4, CBERS-4A, and AMAZONIA-1 satellites for mapping burned areas observed in 2020, 2021 and 2022 in the Chapada dos Veadeiros National Park, by using *Random Forest* for supervised classifications. The time series comprises 235 images integrated into a regular grid, resulting in six independent datasets (NIR, BAI, EVI, GEMI, NDVI, and NDWI) utilized for training, validation, and test. Overall, we observed that NDVI yielded the lowest values of the accuracy metrics adopted and that when assessing the performance of the annual datasets, 2021 delivered the best results, followed by 2020 and 2022. Generalization tests conducted on annual datasets applying multitemporal models, i.e., models containing samples from all three years, produced IoUs above 70% in 2020 (excluding EVI and NDVI) and 2021 (excluding NDVI), and above 60% in 2022 (excluding NDVI).

Keywords: Fire. Remote Sensing. CBERS-4. CBERS-4A. AMAZONIA-1.

1 INTRODUÇÃO

Ecossistemas do bioma Cerrado, um dos dois *hotspots* brasileiros de conservação da biodiversidade (MYERS et al., 2000), abrigam alta diversidade biológica e prestam diversos serviços ecossistêmicos, tais como serviços de provisão e de regulação de água em escala nacional e de estocagem de CO₂, o qual é predominantemente subterrâneo (COLLI et al., 2020, BISPO et al., 2024). O Cerrado evoluiu sob a presença periódica de incêndios naturais, e comunidades de gramíneas nativas de fitofisionomias campestres e savânicas possuem adaptações contra o fogo. O Cerrado é considerado, portanto, um bioma majoritariamente pirofítico, ou seja, adaptado e codependente do fogo (DURIGAN et al., 2020; PIVELLO et al., 2021).

Contudo, incêndios originados por *drivers* antrópicos, que ocorrem em estações desfavoráveis do ano e perduram por períodos maiores de tempo, são mais intensos e ameaçam a biodiversidade do Cerrado, já que espécies podem não resistir à intensidade das chamas e à severidade das queimadas (KEELEY, 2009; FIDELIS et al., 2018). O fogo se tornou mais frequente, intenso e difuso na atualidade, e incêndios antrópicos impactam negativamente sistemas socioecológicos do Cerrado, onde o fogo foi um agente de seleção natural presente ao longo dos últimos quatro milhões de anos, devido a impactos negativos relacionados a incêndios antrópicos originados por conflitos de uso da terra, técnicas agrícolas e práticas recreativas (PIVELLO et al., 2021, RIBEIRO et al., 2024).

O fogo é resultado da combustão, reação química exotérmica que ocorre rapidamente quando dado combustível, composto por material oxidável, reage com determinado comburente, elemento oxidante, como o gás oxigênio. A combustão, para iniciar, requer uma fonte de ignição, combustível disponível à temperatura de queima e a presença de oxidante em concentração suficiente (HOFFMAN et al., 2021, FILKOV et al., 2023). Em incêndios florestais o fogo consome o material orgânico vegetal, combustível que exerce influência na intensidade do fogo e no calor liberado (MCARTHUR; CHENEY, 2015).

Em uma perspectiva de Sensoriamento Remoto (SR), mudanças na configuração da superfície terrestre são contínuas, e áreas queimadas em ecossistemas naturais são entendidas como mudanças abruptas e não permanentes na cobertura vegetal (SHIMABUKURO et al., 2020). Sensores remotos a bordo de satélites detectam e registram a radiação eletromagnética proveniente do sistema terrestre, de acordo com o comportamento espectral e as propriedades dos alvos, e permitem a geração de imagens. Da interação da radiação eletromagnética, refletida ou emitida pelos alvos, e recebida pelo sensor, é possível descrever comportamentos espectrais de alvos em regiões específicas do espectro eletromagnético de acordo com a resolução espectral do sensor, da posição e da amplitude das bandas imageadas (JENSEN, 2009).

Penha (2018) elucida que existem dois principais subprodutos de fogo em aplicações de SR: subprodutos de liberação de calor; e subprodutos de modificações biofísicas dos componentes carbonizados. Enquanto a energia liberada na combustão pode ser detectada por SR na faixa do infravermelho termal e designar focos de calor (SZPAKOWSKI; JENSEN, 2019), o sinal eletromagnético das áreas queimadas pode ser proveniente da energia solar refletida pela superfície queimada e ser detectado em um intervalo mais abrangente, que inclui a região do visível (NEGRI et al., 2022). Características dos sensores determinam as estratégias de processamento de dados de focos de calor ou de áreas queimadas (SZPAKOWSKI; JENSEN, 2019).

De acordo com Epiphanyo (2009), os satélites CBERS (*China-Brazil Earth Resources Satellite*) são satélites de continuidade, o que significa que um dos seus objetivos é garantir a provisão de imagens com características semelhantes ao longo do tempo. O CBERS-1, o primeiro satélite da família CBERS, foi lançado em 1999 e atualmente estão em operação o CBERS-4 (lançado em 2014) e o CBERS-4A (lançado em 2019). Além desses satélites, que são operados conjuntamente por Brasil e China, o AMAZONIA-1 (AMZ-1), que é o primeiro satélite projetado inteiramente no Brasil e operado pelo INPE (Instituto Nacional de Pesquisas Espaciais), foi lançado em 2021 e representa um ativo tecnológico estratégico para o planejamento e ordenamento territorial do país e para a gestão ambiental (SILVA et al., 2022).

O sensor orbital WFI (*Wide Field Imaging Camera*) está na série CBERS desde o primeiro lançamento e, originalmente, operava nas bandas do vermelho e do infravermelho próximo (*near infrared* - NIR) com uma resolução espacial de 260 m. Atualmente, operacionaliza no CBERS-4, CBERS-4A e AMZ-1 nas bandas do azul (0,45-0,52 μm), do verde (0,52-0,59 μm), do vermelho (0,63-0,69 μm) e do NIR (0,77-0,89 μm). A

resolução espacial do WFI é de 64 m no CBERS-4 e AMZ-1, e de 55 m no CBERS-4A, e essa diferença ocorre devido às diferentes altitudes das órbitas dos satélites. Sua combinação permite ao Brasil dispor de uma constelação de sensores capaz de fornecer dados com periodicidade de 1-2 dias. Oldoni (2022) explorou técnicas de harmonização de séries temporais do WFI a bordo desses satélites e chegou à conclusão de que, apesar de serem comparáveis espectral e geometricamente, imagens do WFI dos três satélites não são totalmente equivalentes desde a origem de suas aquisições.

Com base nas bandas imageadas pelo sensor é possível proceder a transformações em que os produtos realcem alvos específicos de interesse. Índices espectrais são obtidos pelo processamento de duas ou mais bandas por meio de técnicas que são, no geral, simples e computacionalmente eficientes (PENHA, 2018). O potencial de detecção de áreas queimadas, no entanto, é reduzido se um determinado sensor, como no caso do WFI, opera somente nas bandas do espectro do visível e do NIR (VNIR). Apesar dessas limitações, Pastor e Shimabukuro (2009) exploraram o uso das bandas do vermelho e do NIR do WFI no mapeamento de áreas queimadas utilizando OBIA (*Object-Based Image Analysis*) e análise de mistura espectral.

O uso de séries temporais de imagens de satélites tem sido explorado no contexto atual de *big data* e da inteligência artificial (IA). O processamento de grandes volumes de dados é um dos benefícios do uso da IA, e isso é igualmente importante em estudos de SR, pois nos últimos anos o paradigma de IA, materializado por técnicas de *machine learning* (ML), foi amplamente adotado no campo das ciências ambientais (STROPPIANA et al., 2021). De acordo com Tiwari et al. (2018), algoritmos de ML permitem que computadores aprendam a partir de dados, possibilitando tarefas de reconhecimento de padrões em *big data* e previsões sobre fenômenos de interesse. Dentre as técnicas principais de classificação de imagens com ML estão os algoritmos de aprendizado supervisionado, como o *Random Forest* (RF), método não paramétrico baseado múltiplas árvores de decisão. Classificadores não paramétricos são amplamente utilizados em estudos de SR, pois os dados raramente satisfazem o pressuposto de normalidade (BELGIU; DRĂGUȚ, 2016).

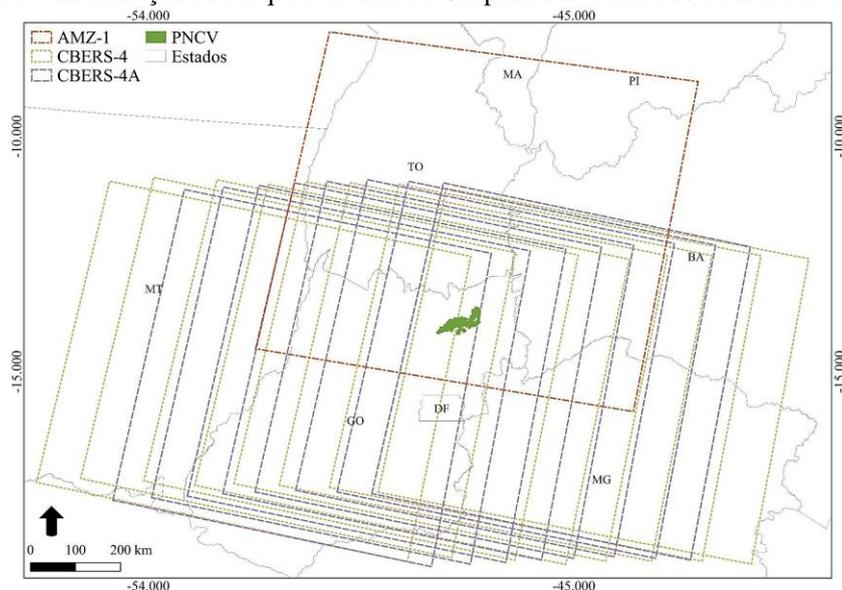
Este artigo propõe que é possível classificar áreas queimadas anuais utilizando séries temporais do sensor WFI e o algoritmo RF. Para testar essa hipótese, é apresentada uma abordagem preliminar de mapeamento anual de áreas queimadas no Cerrado do Parque Nacional da Chapada dos Veadeiros. A estratégia combina amostras aleatórias de diferentes anos das classes “área queimada” e “área não queimada” em conjuntos anuais de dados multitemporais de treinamento e, em seguida, generaliza os modelos a conjuntos inéditos de dados anuais. A metodologia emprega imagens ortoretificadas (*Level-4*) de 2020, 2021 e 2022 da banda NIR e de índices espectrais derivados do WFI a bordo dos satélites CBERS-4, CBERS-4A e AMZ-1. O método proposto ressalta tanto as limitações quanto às potencialidades do uso combinado dos satélites brasileiros e avalia o desempenho do algoritmo RF na classificação supervisionada de áreas queimadas, alvos terrestres influenciados por variações estocásticas e por diferenças de sazonalidade interanuais.

2 MATERIAL E MÉTODOS

2.1 Parque Nacional da Chapada dos Veadeiros

Localizado no nordeste do estado de Goiás, o Parque Nacional da Chapada dos Veadeiros (PNCV) se distribui pelos municípios de Alto Paraíso de Goiás, Cavalcante, Nova Roma, Teresina de Goiás, São João da Aliança e Colinas do Sul. Criado em 1961 pelo Decreto Federal nº 48.875, essa unidade de conservação de proteção integral foi alvo de ampliações e de reduções ao longo do tempo e a sua configuração atual de 240.611 hectares foi estabelecida em 2017 pelo Decreto Federal de 5 de junho. As características florísticas do parque estão ligadas às formações savânicas, conforme destacado por Loebmann (2008), e o Plano de Manejo (ICMBIO, 2021) indica a presença de um mosaico fitofisionômico diversificado, que inclui tanto ecossistemas campestres quanto florestais. O PNCV é observado diretamente por oito órbitas do WFI a bordo do CBERS-4A no ponto 132 e por outras oito órbitas do CBERS-4 no ponto 117. Para o AMZ-1, a órbita 35 cobre a área no ponto 17. A resolução temporal do WFI a bordo dos satélites varia entre 3-5 dias, mas o uso conjunto dos três possibilita adquirir imagens com intervalos de 1-2 dias. A Figura 1 situa geograficamente o PNCV e demonstra a sobreposição dos campos de visada do WFI dos satélites brasileiros para observação dessa região.

Figura 1 – Localização do Parque Nacional da Chapada dos Veadeiros e cobertura do WFI.

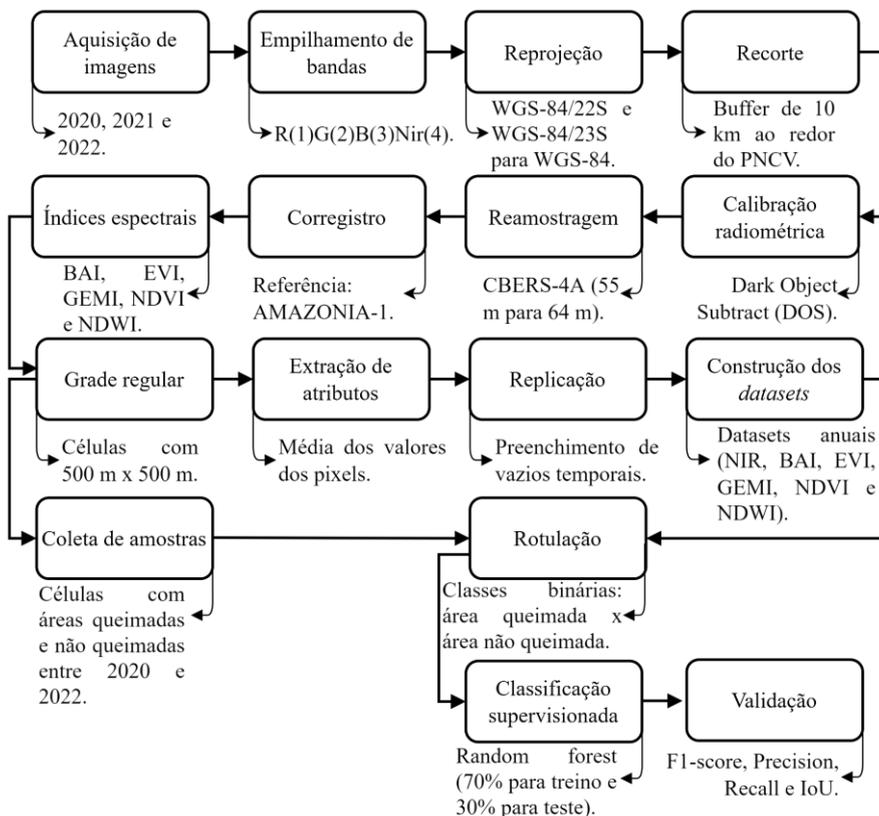


Elaboração: Os autores (2024).

2.2 Fluxograma do processamento

Os procedimentos metodológicos estão delineados no fluxograma da Figura 2. As imagens Nivel-4 (Level-4) do sensor WFI dos satélites CBERS-4, CBERS-4A e AMZ-1 foram adquiridas do catálogo do INPE, utilizando a biblioteca Cbers4asat (RUSSO, 2023) em Python. O período de aquisição abrangeu de 01 de janeiro de 2020 a 31 de dezembro de 2022. Com as bibliotecas Os e Rasterio foram realizados processamentos de normalização das imagens para a área de estudo, que consistiu no empilhamento das bandas (R(1)G(2)B(3)NIR(4)), padronização do sistema de coordenadas geográficas (WGS-84) e recorte para o *bounding box* de referência, que abrange as latitudes de 14°17'44,88"S a 13°32'35,16"S e as longitudes de 47°59'22,92"O a 46°53'19,68"O.

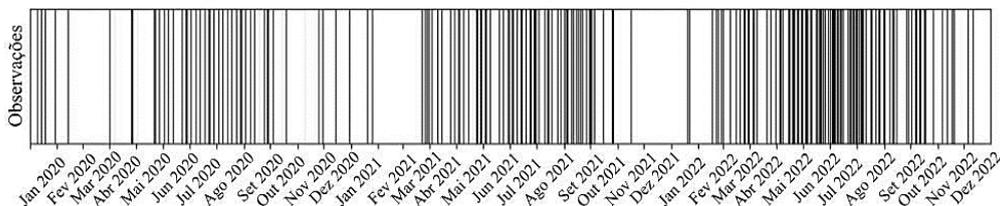
Figura 2 – Fluxograma metodológico.



Elaboração: Os autores (2024).

Das 382 imagens adquiridas pelo catálogo do INPE, 235 foram incluídas na composição da série temporal. No processo de análise visual, 147 imagens foram desconsideradas devido à presença de nuvens, à não cobertura de pelo menos metade do *bounding box* de referência e às duplicidades observadas no ano de 2022, ano em que há imagens dos três satélites. Portanto, a série temporal construída compreendeu: 122 imagens do CBERS-4A, que abrange toda o intervalo de 2020 a 2022; 75 imagens do AMZ-1, disponíveis a partir do dia 27 de março 2021; e 38 imagens do CBERS-4, que apesar de ser o satélite que está a mais tempo em órbita, só tem imagens disponíveis no catálogo do INPE a partir do dia 9 de maio de 2022. A Figura 3 mostra a densidade da série temporal ao longo dos três anos.

Figura 3 – Densidade da série temporal de imagens do WFI.



Elaboração: Os autores (2024).

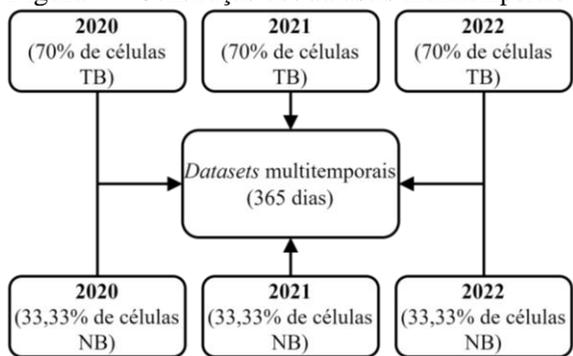
O ano de 2020 contém 50 imagens, enquanto 2021 possui 72 e 2022 registra 113. Os períodos anuais com os menores números de observações ocorrem entre os meses de novembro a março, devido à estação chuvosa e à concentração de nuvens. O pico de observações válidas ocorre em julho, e o período de abril a setembro concentra o maior número de imagens úteis. Esse intervalo coincide com a estação seca, época em que ocorre a maioria dos fogos no Cerrado e que designa a principal janela de observação de áreas queimadas nesse bioma (MATAVELI et al., 2018). Apesar da irregularidade inicial das séries temporais, a replicação dos dados resultou em *datasets* anuais temporalmente regulares com 365 atributos.

Foi aplicada uma correção radiométrica pelo método DOS (*Dark Object Subtract*) (CHAVEZ-JR, 1988; NUNES et al., 2019) nas imagens da série temporal, e as imagens do CBERS-4A foram reamostradas de 55 m para 64 m no intuito de igualar as resoluções espaciais do WFI. A biblioteca Arosics (*Automated and Robust Open-Source Image Co-Registration Software*) (SCHEFFLER, 2017) foi empregada no corregristo automático das imagens, tendo como referência o *grid* do WFI do AMZ-1, com os parâmetros “grid resolution” de 30 *pixels* e “windows size” de 400 x 400 *pixels*, o que totalizou 2.772 possíveis pontos de controle. Foram processados, posteriormente, os índices BAI (*Burned Area Index* (CHUVIECO et al., 2002)), EVI (*Enhancement Vegetation Index* (HUETE et al., 2002)), GEMI (*Global Environmental Monitoring Index* (PINTY; VERSTRAETE, 1992)), NDVI (*Normalized Difference Vegetation Index* (ROUSE et al., 1974)) e NDWI (*Normalized Difference Water Index* (MCFEETERS, 1996)).

Dados da banda do NIR e dos índices espectrais foram integrados em uma grade vetorial com células regulares de 500 m x 500 m, com a utilização das bibliotecas Geopandas (JORDAHL et al., 2020) e Rasterstats para extrair a estatística zonal baseada na média dos valores dos *pixels* dentro das células. Devido à irregularidade da série temporal, e das características das áreas queimadas, que são mudanças de cobertura abruptas e não permanentes, foi adotada a técnica de replicação dos últimos valores válidos observados para o preenchimento das lacunas temporais. Com base em 235 imagens do WFI dos três anos, foram construídos *datasets* com 1.096 colunas, ou dias e, para fins de padronização, foi desconsiderado o dia 31 de dezembro de 2020 (ano bissexto). Por fim, os conjuntos de dados foram divididos em *datasets* anuais (2020, 2021 e 2022) com 365 observações/dias oriundas das imagens de cada ano e nos valores replicados.

Nem todas as células da grade são, necessariamente, preenchidas de forma homogênea por áreas queimadas, dada a anatomia espacial desse alvo e a regularidade das células. Portanto, foram identificadas, por interpretação de imagens, todas as células com áreas queimadas dos três anos e elas foram rotuladas como “células totalmente queimadas” (TQ) ou “células parcialmente queimadas” (PQ), e a data da imagem foi registrada na tabela de atributos. As células que não continham áreas queimadas foram rotuladas como “área não queimada” (NQ). Para o treinamento dos modelos gerados com o RF, as células TQ foram utilizadas como amostras de entrada da classe “área queimada” (AQM) e foi adotada, para fins de validação, a concatenação dos rótulos TQ e PQ na classe AQM. Posteriormente foram gerados, a fim de teste e generalização, *datasets* multitemporais para cada plano de informações (NIR, BAI, EVI, GEMI, NDVI e NDWI) com parte das amostras das classes binárias AQM e ANQ observadas em cada um dos três anos (Figura 4)

Figura 4 – Construção dos *datasets* multitemporais.



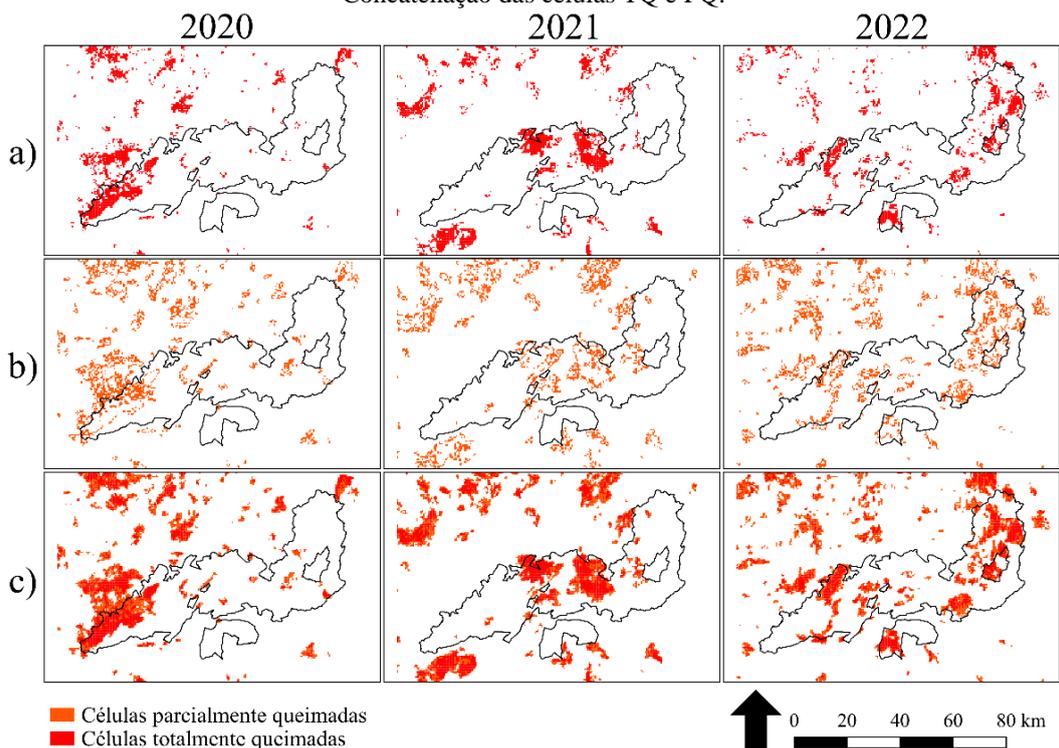
Elaboração: Os autores (2024).

Esses *datasets* contêm 70% de células TQ e 33,33% de células NQ selecionadas aleatoriamente de cada ano e englobam 365 observações/dias. As classificações supervisionadas foram conduzidas com o algoritmo RF nos *datasets multitemporais* de cada plano de informação e a rotina implementada usou a biblioteca Scikit-learn (PEDREGOSA et al., 2011). Para as classificações foram destinadas 60% das amostras de ambas as classe para treinamento e 40% para validação, e o GridSearchCV foi empregado na busca dos melhores hiperparâmetros relacionados ao “n_estimator”, que variou entre 100, 200 e 300 árvores de decisão, e ao “max_depth”, que variou entre 3, 5 e 7 graus de profundidade.

Foi utilizada uma divisão balanceada de 2.814 amostras por classe binária (AQM e ANQ), o que totalizou 5.628 amostras totais. O número 2.814 reflete a quantidade de 60% das células TQ dos *datasets* multitemporais (rótulo da classe AQM) construídos a partir da concatenação dos 70% das células totalmente atingidas por fogo provenientes dos anos de 2020, 2021 e 2022. Para cada um dos planos de informação foram realizadas cinco classificações que utilizaram conjuntos de amostras selecionados aleatoriamente pelo RF, o que possibilitou a análise dos resultados a partir da estatística descritiva de média e desvio padrão.

Por fim, os modelos criados a partir dos *datasets* multitemporais foram generalizados sobre os *datasets* anuais, e no processo de validação foram analisadas as métricas *F1-score*, *precision*, *recall*, IoU (*Intersection over Union*), erros de omissão, erros de comissão e o teste pareado de McNemar. A Figura 5 contém as células com áreas queimadas anuais identificadas manualmente.

Figura 5 – Mapeamentos manuais das áreas queimadas do PNCV entre 2020 e 2022. a: Células TQ; b: Células PQ; c: Concatenação das células TQ e PQ.



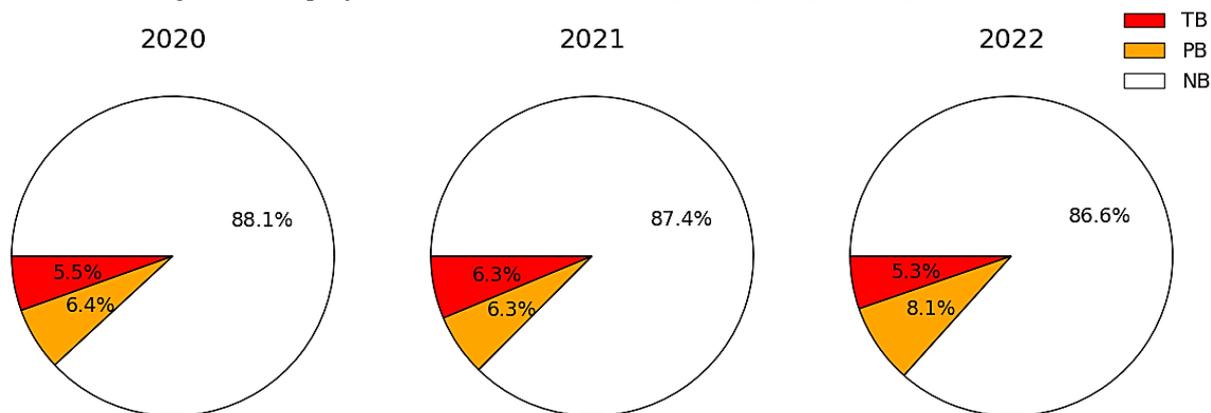
Elaboração: Os autores (2024).

3 RESULTADOS E DISCUSSÃO

3.1 Classificação dos *datasets* multitemporais

O que se constata, quando quantificada a proporção das 38.957 células da grade atingidas anualmente de forma total ou parcial por fogo (Figura 6), é que 2020 possui 5,5% de células TQ e 6,4% de células PQ (11,9% das células da grade); 2021 possui 6,3% de células TQ e a mesma porcentagem de células PQ (12,6%); e 2022 contém 5,3% de células TQ e 8,1% de células PQ (13,4%).

Figura 6 – Proporção de amostras das classes AQM (TQ e PQ) e ANQ dos três anos.



Elaboração: Os autores (2024).

A Tabela 1 sumariza os resultados obtidos após a realização das cinco classificações de cada um dos *datasets* multitemporais do NIR, BAI, EVI, GEMI, NDVI e NDWI, estimados com base nos 40% das amostras reservados previamente para o teste, isto é, 1.878 amostras por classe binária (AQM x ANQ).

Tabela 1 – Resultados obtidos por *dataset* multitemporal e por rodada de classificação.

	Rodada 1	Rodada 2	Rodada 3	Rodada 4	Rodada 5	Desvio padrão	Média
NIR							
Precision BA	0,92	0,91	0,93	0,9	0,9	0,013	0,91
Recall BA	0,91	0,9	0,91	0,92	0,89	0,011	0,91
Precision NB	0,91	0,9	0,91	0,92	0,9	0,008	0,91
Recall NB	0,92	0,91	0,93	0,9	0,9	0,013	0,91
F1-score	0,92	0,9	0,92	0,91	0,9	0,01	0,91
BAI							
Precision BA	0,89	0,91	0,91	0,91	0,91	0,008	0,91
Recall BA	0,91	0,93	0,92	0,92	0,94	0,011	0,92
Precision NB	0,91	0,93	0,92	0,92	0,94	0,011	0,92
Recall NB	0,89	0,91	0,91	0,91	0,91	0,008	0,91
F1-score	0,9	0,92	0,91	0,91	0,92	0,008	0,91
EVI							
Precision BA	0,91	0,9	0,92	0,91	0,91	0,007	0,91
Recall BA	0,91	0,91	0,91	0,91	0,9	0,004	0,91
Precision NB	0,91	0,91	0,91	0,91	0,9	0,004	0,91
Recall NB	0,91	0,9	0,92	0,91	0,91	0,007	0,91
F1-score	0,91	0,91	0,91	0,91	0,91	0	0,91
GEMI							
Precision BA	0,91	0,9	0,91	0,92	0,91	0,007	0,91
Recall BA	0,93	0,93	0,91	0,92	0,92	0,008	0,92
Precision NB	0,93	0,93	0,91	0,92	0,92	0,008	0,92
Recall NB	0,91	0,9	0,91	0,92	0,91	0,007	0,91
F1-score	0,92	0,91	0,91	0,92	0,91	0,005	0,91
NDVI							
Precision BA	0,86	0,87	0,88	0,88	0,88	0,008	0,87
Recall BA	0,91	0,91	0,89	0,91	0,91	0,008	0,91
Precision NB	0,91	0,9	0,89	0,91	0,9	0,008	0,90

	Rodada 1	Rodada 2	Rodada 3	Rodada 4	Rodada 5	Desvio padrão	Média
<i>Recall</i> NB	0,86	0,86	0,88	0,87	0,87	0,008	0,87
<i>F1-score</i>	0,89	0,88	0,88	0,89	0,89	0,005	0,87
NDWI							
<i>Precision</i> BA	0,93	0,92	0,92	0,92	0,91	0,007	0,9
<i>Recall</i> BA	0,91	0,92	0,91	0,92	0,92	0,005	0,92
<i>Precision</i> NB	0,92	0,93	0,91	0,92	0,92	0,007	0,92
<i>Recall</i> NB	0,93	0,93	0,92	0,92	0,91	0,008	0,92
<i>F1-score</i>	0,92	0,93	0,92	0,92	0,91	0,007	0,92

Elaboração: Os autores (2024).

O *dataset* do NDWI apresentou o melhor desempenho quanto à média da métrica *F1-score* (0,92), enquanto o NIR, BAI, EVI e GEMI retornaram o mesmo valor de *precision* (0,91) médio. É possível observar que áreas não queimadas tendem a retornar valores de *precision* superiores às áreas queimadas, contudo resultados menores de *recall*, das áreas não queimadas, indicam que mais células não queimadas se confundem com áreas queimadas do que o inverso. O único *dataset* que retornou um *F1-score* inferior a 0,9 foi o NDVI (0,87). De forma geral, o *precision* da classe AQM do NIR retornou o maior desvio padrão após as cinco classificações, sendo quase duas vezes superior ao desvio padrão dos *datasets* NDWI, GEMI e EVI. O EVI e o NDWI obtiveram as menores variabilidades do *recall* da classe AQM, que é cerca da metade dos demais *datasets*. O EVI demonstrou possuir os mais constantes valores de *F1-score* após as classificações. Esses resultados fornecem indícios do comportamento do classificador frente a *datasets* multitemporais e a conjuntos balanceados criados com amostras aleatórias das classes AQM e ANQ, e elucidam que nenhum dos seis planos de informação retornou *F1-scores* inferiores a 0,85 e superior a 0,93.

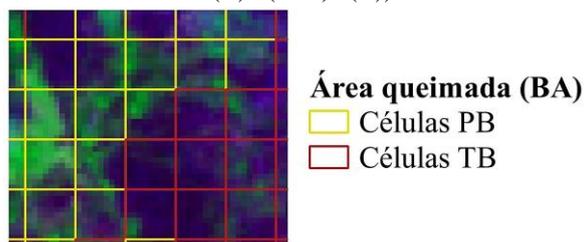
Das análises das médias das métricas *precision* e *recall* da classe AQM entre os *datasets* é possível visualizar menor eficiência do NDVI em diferenciar corretamente áreas queimadas de áreas não queimadas. O *precision* de 0,87 e o *recall* de 0,91 fornecem indícios de que o classificador diminui o seu desempenho no momento de classificar as amostras que foram rotuladas com AQM, que acabam sendo classificadas como ANQ. O *recall* superior indica que, apesar de ocorrer essa falha em se detectar verdadeiros positivos, quando a validação usa 30% das amostras ela verifica que células AQM estão sendo identificadas corretamente como AQM. Sem embargo, a implicação dessa constatação é que células ANQ estão erroneamente sendo rotuladas como AQM (falsos positivos). Analisando o *precision* e *recall* da classe ANQ das classificações do NDVI é constatado que esse *dataset* retorna, igualmente, os resultados mais baixos, o que está alinhado com um *F1-score* inferior aos demais *datasets*, por ser essa uma métrica harmônica entre *precision* e *recall*. Enquanto o *precision* de AQM é inferior ao *recall*, o *precision* de ANQ é superior ao *recall*, e esse menor *recall* da ANQ pode ser explicado por falhas na identificação de células NQ, que são classificadas como AQM.

3.2 Generalização e validação

Depois das classificações dos *datasets* multitemporais, os modelos obtidos foram generalizados sobre os *datasets* anuais. Ao combinar amostras dos três *datasets* (2020, 2021 e 2022) o modelo é exposto a uma maior diversidade de cenários, permitindo que ele aprenda tanto os padrões recorrentes quanto as variações interanuais das queimadas. Dessa forma, é esperado que o RF se torna mais apto a generalizar, identificando áreas queimadas em diferentes anos, ainda que os eventos não ocorram nos mesmos períodos ou que não sejam linearmente separáveis.

A métrica *Intersection over Union* (IoU) foi adotada na avaliação dos resultados desses testes e considerou dois mapeamentos de referência: o mapeamento manual que contém apenas as células TQ (Figura 3a) como representante da classe AQM e o mapeamento que contém a concatenação das células TQ e PQ (Figura 5c) como representantes da classe AQM. O comportamento espectral de células PQ varia em conformidade com a proporção espacial (a área da célula) que é efetivamente queimada e segundo o sinal espectral e a mistura dos alvos existentes no interior da célula, e que são adjacentes às áreas queimadas contidas em seu interior, conforme ilustra a Figura 7.

Figura 7 – Exemplos de células TQ e células PQ em imagens do WFI com 64 m de resolução espacial (composição: R(R)G(NIR)B(B)).



Elaboração: Os autores (2024).

A validação baseada na referência que inclui os dois rótulos de células afetadas por fogo (TQ + PQ) pode superestimar a extensão de áreas queimadas na paisagem, e isso é um fator que deve ser considerado em estudos que buscam descrever, ou compreender, padrões de áreas queimadas utilizando grades regulares. Considera-se, para fins de validação do presente estudo, que células PQ designam, juntamente com células TQ, alvos da classe AQM. A Tabela 2 resume os resultados dos três anos obtidos com as generalizações dos modelos multitemporais, considerando o IoU global dos testes validados a partir dos dois mapeamentos de referência citados anteriormente. Ao analisar os IoUs obtidos com a referência TQ + PQ é possível perceber que, no geral, os *datasets* de 2021, que incluem imagens do CBERS-4A e do AMZ-1, obtiveram as melhores correspondências globais, seguidos dos *datasets* de 2020 e 2022. Considerando esse mapeamento de referência se verifica que apenas as generalizações sobre os *datasets* de 2020 do EVI e do GEMI retornaram correspondências menores do que a referência que utiliza apenas células TQ para representar a classe AQM.

Tabela 2 – Síntese dos resultados de IoU obtidos dos testes sobre os *datasets* anuais.

	IoU	
	TQ	TQ + PQ
NIR (2020)	0,7	0,72
NIR (2021)	0,68	0,75
NIR (2022)	0,61	0,67
BAI (2020)	0,67	0,7
BAI (2021)	0,62	0,7
BAI (2022)	0,59	0,67
EVI (2020)	0,7	0,68
EVI (2021)	0,69	0,73
EVI (2022)	0,58	0,62
GEMI (2020)	0,72	0,7
GEMI (2021)	0,68	0,72
GEMI (2022)	0,56	0,63
NDVI (2020)	0,6	0,63
NDVI (2021)	0,65	0,69
NDVI (2022)	0,53	0,58
NDWI (2020)	0,65	0,7
NDWI (2021)	0,72	0,76
NDWI (2022)	0,59	0,65

Elaboração: Os autores (2024).

Os *datasets* de 2020 retornaram IoUs superiores quando comparados aos testes nos *datasets* de 2022, ano em que, devido à disponibilidade de imagens do CBERS-4, ocorre o maior número de imagens da série. Uma hipótese que talvez justifique os desempenhos inferiores dos *datasets* de 2022 é o aumento da variabilidade dos dados em intervalos temporais mais curtos, pois quanto maior o número de imagens ao longo de um ano, menor é a quantidade de observações replicadas e, logo, maior é a robustez da série temporal. Nesse estudo, 2020 e 2021 têm mais observações replicadas do que 2022, e os *datasets* multitemporais, por consequência, refletem essa constatação. Para compreender as implicações da utilização conjunta do sensor WFI a bordo dos três satélites existe a necessidade de que o INPE agregue ao seu catálogo as imagens do CBERS-4 anteriores a 2022, pois dessa forma apenas o ano de 2020 teria integralmente um menor número de imagens disponíveis (CBERS-4 e CBERS-4A), visto que o AMZ-1 entrou em operação em 2021.

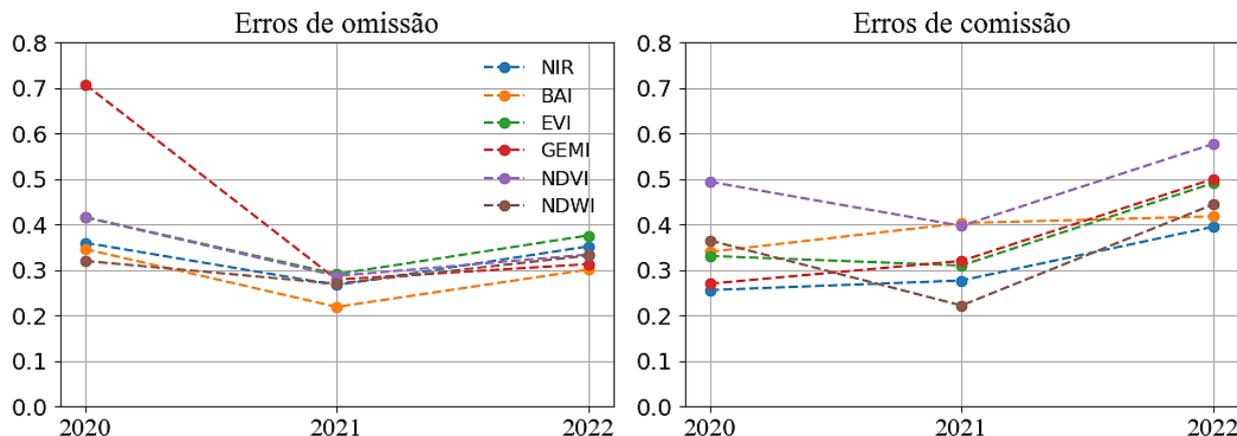
Considerando que células PQ não caracterizam alvos espectralmente homogêneos, e que a diferença da quantidade entre células TQ e PQ é maior em 2022 (5,3% e 8,1%, respectivamente), é possível ponderar que os modelos construídos com base em amostras de entrada contendo apenas células TQ geraram confusões entre as classes AQM e ANQ, segundo é indicado pelos menores valores de IoU dos *datasets* desse ano. Neste sentido, células PQ representariam uma categoria intermediária entre as classes AQM e ANQ e, independentemente da classe à que elas estejam associadas, é esperado que células PQ reduzam a qualidade das amostras de treinamento em classificações binárias. Nos testes conduzidos, o NDVI demonstrou ser o índice em que esse desafio é maior, dadas às performances inferiores observadas nos três anos. Uma abordagem passível de ser testada, e que seja baseada em células regulares, poderia explorar o desempenho do classificador e das generalizações a partir do uso de três classes, em que as células PQ designariam um conjunto de amostras independente.

Compreender os impactos do fogo na paisagem utilizando ferramentas de SR envolve a utilização de produtos de áreas queimadas globais ou regionais, que geralmente são binários e destinados a intervalos de tempo pré-definidos, como dias, meses ou anos. Um desafio significativo associado ao sensor WFI, e talvez seja o maior, é a falta de uma banda espectral na região do infravermelho de ondas curtas (SWIR), o que limita a geração de índices espectrais clássicos, como o NBR (*Normalized Burn Ratio*). Portanto, com o sensor WFI, as propriedades das células PQ devem ser interpretadas com base na mistura espectral inerente a elas apenas nas bandas do visível e do NIR e nos índices passíveis de processamento. Cada produto de área queimada é o resultado de algoritmos específicos, e é esperado que apresentem variações devido às diferenças metodológicas (SHIMABUKURO et al., 2020). É importante ressaltar que a utilização de células regulares, juntamente com a baixa resolução espectral do WFI, requer cuidado especial em relação às células PQ e que esse alvo não pode ser negligenciado, pois tem aplicações possíveis em análises acerca da severidade de queimadas, por exemplo.

A Figura 8, elaborada a partir da quantificação dos verdadeiros positivos (*true positives*), falsos positivos (*false positives*) e falsos negativos (*false negatives*) da classe AQM, evidencia a comparação dos erros de omissão e de comissão nos testes sobre os *datasets* anuais. A análise dos erros de omissão dos *datasets* de 2020 revela que o GEMI retornou o maior erro (70,8%) e que os demais índices variaram entre 32% e 34,6%, exceto o NDVI (41,6%) e o EVI (41,6%). Os *datasets* de 2021 retornaram erros de omissão entre 21,9% (BAI), *dataset* com menor erro, e 29,1% (EVI). Os erros de omissão de 2022 variaram entre 30,1% e 37,6% e, como aconteceu em 2021, o BAI e o EVI tiveram, respectivamente, os menores e os maiores erros desse tipo.

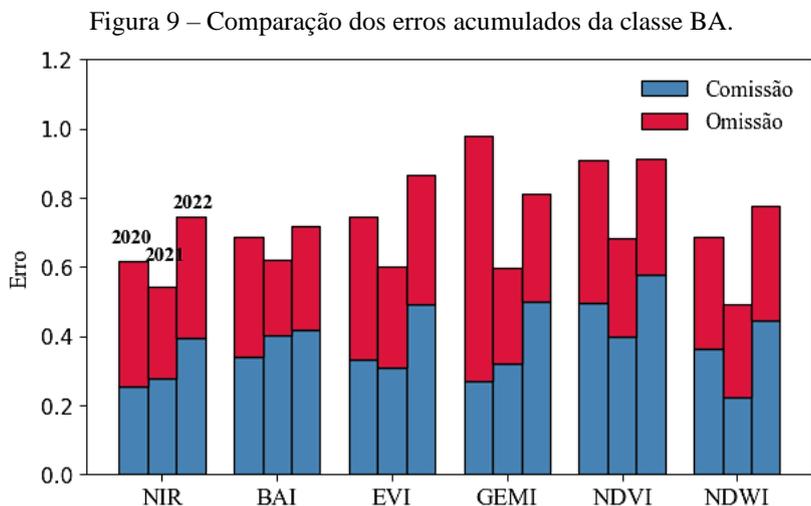
A análise dos erros de comissão indica maior variabilidade dos resultados entre os anos nesse tipo de erro do que no caso dos erros de omissão, ou seja, ocorre maior variabilidade na identificação de falsos positivos da classe AQM do que verdadeiros positivos. O NDVI teve em 2020 o pior desempenho com 49,4%, enquanto os demais *datasets* variaram entre 25,6% (NIR) e 36,5% (NDWI). Em 2021, a amplitude dos erros de comissão ficou entre 22,2% (NDWI) e 40,3% (BAI). Em 2022 são observados os piores desempenhos na identificação correta de áreas queimadas, sendo que o NIR retornou o menor erro (39,5%) e o NDVI o maior (57,7%).

Figura 8 – Comparação dos erros de comissão e omissão da classe AQM por *dataset* anual generalizado.



Elaboração: Os autores (2024).

De forma geral, o desempenho do GEMI em 2020 contrasta com os demais *datasets* testados, pois a diferença nos erros de omissão, que ultrapassa 35%, não é observada nessa magnitude em nenhum dos outros anos ou *datasets*. Os erros de comissão indicam que os *datasets* tendem a variar mais entre si nesse tipo de erro do que nos erros de omissão. Erro de comissão, no caso da análise da classe AQM, ocorre quando a generalização identifica, incorretamente, uma célula que pertence à classe NB como pertencente à classe AQM (falso positivo). Por sua vez, ocorre um erro de omissão quando a generalização deixa de identificar uma célula que pertence, verdadeiramente, à classe AQM e a classifica como pertencente à classe NB (falso negativo). A Figura 9 ilustra a sobreposição dos erros por *dataset* anual.



Elaboração: Os autores (2024).

O ano de 2021 foi o que retornou o menor erro acumulado, entre comissão e omissão, observado em todos os *datasets*. A análise dos anos de 2020 e 2022 evidencia que, com exceção do GEMI, que teve desempenho inferior em 2020 em relação à 2022, e do NDVI, que retornou resultados semelhantes em ambos os anos, todos os demais *datasets* de 2022 obtiveram erros acumulados superiores do que os observados em 2020. Dessa forma, é possível inferir que os *datasets* de 2021 são os que performaram melhor a partir das generalizações dos modelos multitemporais, seguidos pelos *datasets* de 2020 e 2022, respectivamente. O índice NDWI de 2021, com um erro acumulado de 49,2%, foi o *dataset* generalizado com o melhor desempenho. A Tabela 3 exibe as matrizes de confusão das generalizações validadas a partir do mapeamento de referência que considera a concatenação das células TQ e PQ na composição da classe AQM.

Tabela 3 – Matrizes de confusão obtidas pela generalização dos *datasets* anuais.

	2020 (TQ+PQ)		2021 (TQ + PQ)		2022 (TQ + PQ)	
	BA	NB	BA	NB	BA	NB
NIR						
BA	2.975	1.027	3.591	1.376	3.384	2.218
NB	1.674	33.281	1.313	32.677	1.844	31.511
BAI						
BA	3.039	1.567	3.830	2.596	3.650	2.622
NB	1.610	32.741	1.074	31.457	1.578	31.107
EVI						
BA	2.713	1.344	3.474	1.563	3.259	3.145
NB	1.936	32.964	1.430	32.490	1.969	30.584
GEMI						
BA	2.716	1.007	3.532	1.668	3.590	3.597
NB	1.933	33.301	1.372	32.385	1.638	30.132
NDVI						
BA	3.010	2.945	3.493	2.307	3.477	4.744
NB	1.639	31.363	1.411	31.746	1.751	28.985
NDWI						
BA	3.157	1.815	3.532	1.010	3.488	2.786
NB	1.492	32.493	1.372	33.043	1.740	30.943

Elaboração: Os autores (2024).

Para verificar se, com base no mapeamento de referência TQ + PQ, há diferenças nos erros das generalizações quando analisadas par a par, foi aplicado o teste de McNemar, cuja hipótese nula (H_0) é de que não é possível afirmar que determinada classificação possui desempenho superior à outra quando comparados pares de classificações com uma mesma referência. A Tabela 4 elenca os resultados em que se aceita H_0 quando o nível de significância é de 95% ($\alpha = 0,05$), ou seja, quando dois pares são significativamente similares. Em 2020, o único par de *datasets* que não demonstrou diferenças significativas nos erros foi o par BAI e NDWI, e em 2021 foi o par NIR e EVI e o par NIR e GEMI. As demais comparações retornaram p-valores inferiores a 0,05, o que permite rejeitar H_0 e aceitar a hipótese alternativa de que há diferenças estatisticamente significativas nos demais erros dos pares anuais obtidas por generalização dos modelos multitemporais.

Tabela 4 – Resultados do teste de McNemar.

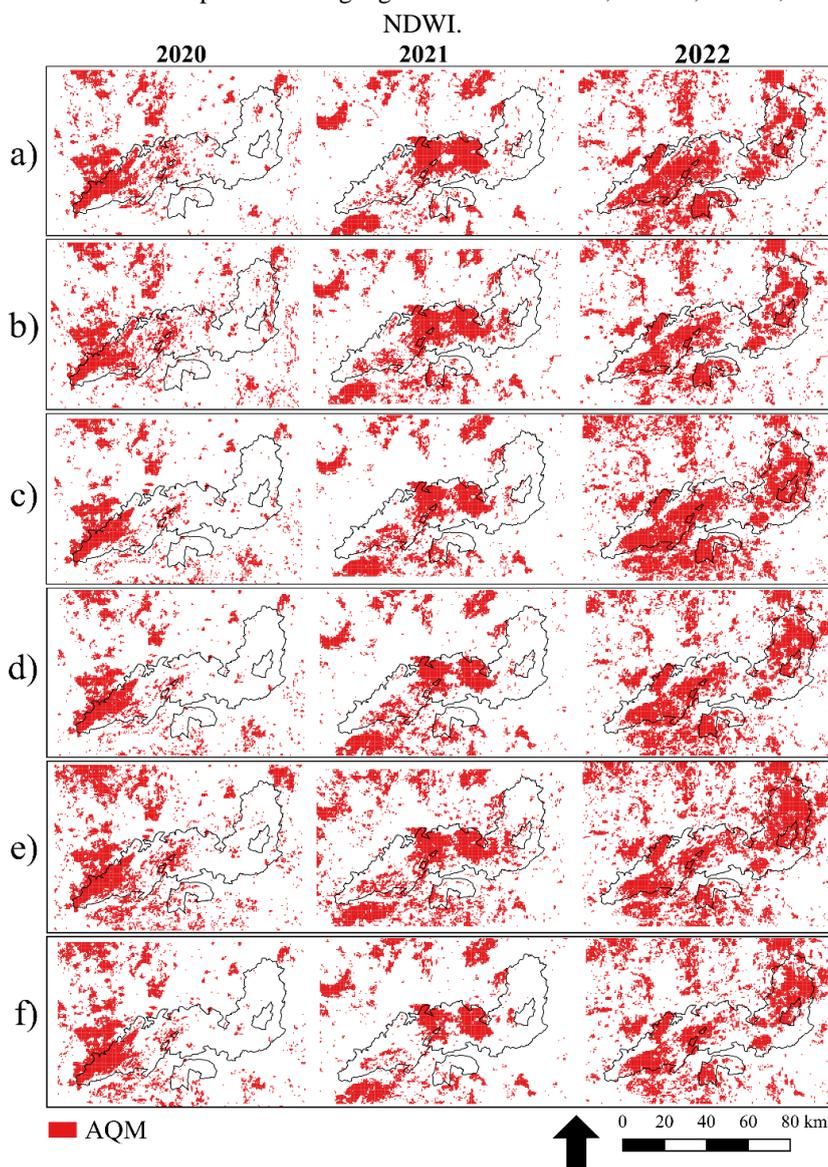
Ano	Classificação 1	Classificação 2	p-valor
2020	BAI	NDWI	0,301
2021	NIR	EVI	0,893
2021	NIR	GEMI	0,289

H_0 : Nenhuma das duas classificações tem um desempenho superior à outra.

Elaboração: Os autores (2024).

A Figura 10 ilustra os resultados das generalizações dos modelos multitemporais sobre os *datasets* anuais sem qualquer processamento de pós-classificação.

Figura 10 – Resultados dos testes espacializados geograficamente. a: NIR; b: BAI; c: EVI; d: GEMI ; e: NDVI; f:



Elaboração: Os autores (2024).

4 CONSIDERAÇÕES FINAIS

É possível mapear, utilizando o algoritmo RF, áreas queimadas observadas pelo sensor WFI com séries temporais provenientes dos satélites CBERS-4, CBERS-4A e AMZ-1. O RF gera um conjunto de árvores de decisão, cada uma treinada com subconjuntos de dados aleatórios (*bagging*), que favorece a criação de modelos e generalizações, além de poder reduzir o risco de *overfitting* do conjunto completo. A análise das árvores individuais permite identificar as características mais relevantes para a classificação (aquelas mais frequentemente utilizadas nas decisões das árvores) e avaliar a confiabilidade da classificação de cada amostra, com base no consenso entre as árvores. Assim, quanto maior for a diversidade e a relevância das amostras de áreas queimadas para treinamento, melhor será a possibilidade de mapeamento utilizando o RF.

O número limitado de bandas e a ausência do SWIR exigem, contudo, diferentes abordagens baseadas em SR e que empreguem principalmente a banda do NIR, pois é a que registra a maior resposta espectral da vegetação. Áreas queimadas respondem espectralmente no SWIR diferentemente de outros alvos, e nas regiões do visível e do NIR elas podem ser confundidas com sombra e água, devido à baixa reflectância nesses comprimentos de onda. A presente abordagem é aplicável à definição que considera o alvo “áreas queimadas” como sendo mudanças abruptas e não permanentes na cobertura vegetal que podem ser detectadas em séries temporais criadas a partir das bandas VNIR.

O uso de células regulares maiores que os *pixels* originais das imagens WFI facilita a integração de dados de satélites brasileiros e exige pré-processamento. No mapeamento binário (área queimada x não queimada), é necessário rotular células parcialmente queimadas como AQM ou ANQ, o que afeta a precisão das classificações. Testes com dados multitemporais mostraram maior acurácia quando os modelos são treinados com células totalmente queimadas representando a classe AQM, e a generalização melhora ao considerar células total e parcialmente queimadas na classe AQM, reduzindo a confusão entre AQM e ANQ, apesar da ocorrência de falsos positivos da classe de áreas queimadas. O NDVI teve o pior desempenho entre os *datasets* analisados e os *datasets* da banda do NIR tiveram desempenhos equivalentes aos dos índices.

Em síntese, uma metodologia viável de mapeamento de áreas queimadas utilizando séries temporais de imagens do WFI, integradas em células regulares, permitiria explorar as bandas do vermelho e do NIR imageadas pelo WFI desde o início da família CBERS. Essa metodologia possibilitaria mapeamentos anuais de áreas queimadas com imagens históricas do CBERS e representaria um ativo tecnológico brasileiro de relevância para a gestão ambiental e territorial. Ressalta-se, porém, a necessidade de o INPE atualizar seu catálogo com imagens do CBERS-4 anteriores ao ano de 2022, tornando possível compreender com maior precisão as influências da inclusão das imagens *Level-4* dos três satélites nas séries temporais do WFI.

Outra perspectiva é que estudos futuros desenvolvam testes e análises baseados em segmentações temporais, eliminando o uso de células regulares e permitindo o aproveitamento das resoluções espaciais atuais do WFI, que é de 55 m no CBERS-4A e de 64 m no CBERS-4 e AMZ-1. Seria possível, nesse caso, utilizar imagens de baixa resolução espacial (≤ 64 m), provenientes das bandas VNIR, com alta resolução temporal (1-3 dias) para fins de mapeamento de áreas queimadas. Por fim, outras abordagens de classificação, como aquelas baseadas na arquitetura *Long Short Term Memory* (LSTM) de redes neurais recorrentes (RNR), podem ser testadas, considerando que a alta resolução temporal desse sensor permite a utilização de janelas temporais curtas, o que abriria possibilidades de mapeamentos mensais ou semestrais, por exemplo.

Agradecimentos

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP, número de processo: 09118-6/2023) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq, número de processo: 302205/2023-3).

Contribuição dos autores

Conceitualização: A. C. O. Metodologia: A. C. O e T. S. K. Redação: A. C. O., B. O. R. e C. A. M. C. Ilustração: A. C. O. Supervisão: T. S. K. Revisão: A. C. O., B. O. R., C. A. M. C. e T. S. K.

Conflito de Interesse

Os autores declaram que não há conflitos de interesse.

Referências

- BELGIU, M.; DRĂGUȚ, L. Random forest in remote sensing: a review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016. DOI: <https://doi.org/10.1016/j.isprsjprs.2016.01.011>.
- BISPO, P. C.; PICOLI, M. C. A.; MARIMON, B. S.; JUNIOR, B. H. M.; PERES, C. A.; MENOR, I. O.; SILVA, D. E.; MACHADO, F. F.; ALENCAR, A. A. C.; ALMEIDA, C. A.; ANDERSON, L. O.; ARAGÃO, L. E. O. C.; BREUNIG, F. M.; DALAGNOL, R.; DINIZ-FILHO, J. A. F.; FERREIRA, L. G.; FERREIRA, M. E.; FISCH, G.; GALVÃO, L. S.; GIAROLLA, A.; GOMES, A. R.; JUNIOR, P. M.; KUCK, T. N.; LEHMANN, C. E. R.; LEMES, M. R.; LIESENBERGM V.; LOYOLA, R.; MACEDO, M. N.; MENDES, F. S.; MIRANDA, F. S.; MIRANDA, S. C.; MORTON, D. C.; MOURA, Y. M.; OLDEKOP, J. A.; RAMOS-NETO, M. B.; ROSAN, T. M.; SAATCHI, S.; SANO, E. E.; SEGURA-GARCIA, C.; SHIMBO, J. Z.; SILVA, T. S. F.; TREVISAN, D. P.; ZIMBRES, B.; WIEDERKEHR, N. C.; SILVA-JUNIOR, C. H. L. Overlooking vegetation loss outside forests imperils the Brazilian Cerrado and other non-forest biomes. **Nature Ecology & Evolution**, v. 8, n. 1, p. 12-13, 2024, DOI: <https://doi.org/10.1038/s41559-023-02256-w>.
- CARVALHO JÚNIOR, O. A. de C.; GUIMARÃES, R. F.; SILVA, C. R.; GOMES, R. A. T. Standardized time-series and interannual phenological deviation: New techniques for burned-area detection using long-term MODIS-NBR dataset. **Remote Sensing**, v. 7, n. 6, p. 6950–6985, 2015, DOI: <https://doi.org/10.3390/rs70606950>.
- CHAVEZ-JR, P. S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, v. 24, n. 3, p. 459–479, 1988.
- CHUVIECO, E.; MARTIN, M. P.; PALACIOS, A. Assessment of different spectral indices in the red-near-infrared spectral domain for burned land discrimination. **International Journal of Remote Sensing**, v. 23, n. 23, p. 5103–5110, 2002. DOI: <https://doi.org/10.1080/01431160210153129>.
- COLLI, G. R.; VIEIRA, C. R.; DIANESE, J. C. Biodiversity and conservation of the Cerrado: recent advances and old challenges. **Biodiversity and Conservation**, v. 29, n. 5, p. 1465–1475, 2020, DOI: <https://doi.org/10.1007/s10531-020-01967-x>.
- COPPIN, P.; LAMBIN, E.; JONCKHEERE, I.; MUYS, B. Digital change detection methods in natural ecosystem monitoring: A review. **International Journal of Remote Sensing**, v. 25, n. 9, 2004, p. 1565-1596, DOI: <https://doi.org/10.1080/0143116031000101675>.
- DURIGAN, G.; PILON, N. A. L.; ABREU, R. C. R.; HOFFMANN, W. A.; MARTINS, M.; FIORILLO, B. F.; ANTUNES, A. Z.; CARMIGNOTTO, A. P.; MARAVALHAS, J. B.; VIEIRA, J.; VASCONCELOS, H. L. No net loss of species diversity after prescribed fires in the Brazilian savanna. **Frontiers in Forests and Global Change**, v. 3, p. 13, 2020, DOI: <https://doi.org/10.3389/ffgc.2020.00013>.
- EPIPHANIO, J. C. N. CBERS: estado atual e futuro. In: Simpósio Brasileiro de Sensoriamento Remoto, XIV, São José dos Campos, 2009. **Anais...** São José dos Campos, Brasil, 2009, p. 2001-2008.
- FIDELIS, A.; ALVARADO, S. T.; BARRADAS, A. C. S.; PIVELLO, V. R. The year 2017: Megafires and management in the Cerrado. **Fire**, v. 1, n. 3, p. 49, 2018, DOI: <https://doi.org/10.3390/fire1030049>.
- FILKOV, A. I.; TIHAY-FELICELLI, V.; MASOUDVAZIRI, N.; RUSH, D.; VALENCIA, A.; WANG, Y.; BLUNCK, D. L.; VALERO, M. M.; KEMPNA, K.; SMOLKA, J.; DE BEER, J.; CAMPBELL-LOCHRIE, Z.; CENTENO, F. R.; IBRAHIM, M. A.; LEMMERTZ, C. K.; TAM, W. C. A review of thermal exposure and fire spread mechanisms in large outdoor fires and the build environment. **Fire Safety Journal**, v. 140, 2023, DOI: <https://doi.org/10.1016/j.firesaf.2023.103871>.
- HOFFMAN, C.; FERNANDES, P.; MORGAN, P.; REGO, F. C. **Fire science: from chemistry to**

- landscape management**. 1. ed. Switzerland: Springer, 2021.
- INSTITUTO CHICO MENDES DE CONSERVAÇÃO DA BIODIVERSIDADE (ICMBIO). Plano de manejo do Parque Nacional da Chapada dos Veadeiros. Brasília: ICMBIO, 2021. JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. 1. ed. São José dos Campos: Parêntese Editora, 2009.
- JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese, 2009. 598 p. 2.
- JORDAHL, K.; BOSSCHE, J. V. D.; FLEISCHMANN, M.; WASSERMAN, J.; MCBRIDE, J.; GERARD, J.; TRATNER, J.; PERRY, M.; BADARACCO, A. G.; FARMER, C.; HJELLE, G. A.; SNOW, A. D.; COCHRAN, M.; GILLIES, S.; CULBERTSON, L.; BARTOS, M.; EUBANK, N.; MAXALBERT; BILOGUR, A.; REY, S.; REN, C.; ARRIBAS-BEL, D.; WASSER, L.; WOLF, L. J.; JOURNOIS, M.; WILSON, J.; GREENHALL, A.; HOLDGRAF, C.; FILIPE; LEBLANC, F. *geopandas/geopandas*: v0.8.1. jul. 2020. DOI: <https://doi.org/10.5281/zenodo.3946761>.
- HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 195–213, 2002. DOI: [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)
- KEELEY, J. E. Fire intensity, fire severity and burn severity: a brief review and suggested usage. **International Journal of Wildland Fire**, v. 18, n. 1, p. 116-126, 2009, DOI: <https://doi.org/10.1071/WF07049>.
- LOEBMANN, D. G. S. W. Classificação fitofisionômica do Cerrado no Parque Nacional da Chapada dos Veadeiros, GO, com a aplicação de uma análise combinatória com filtros adaptativos em imagens TM LANDSAT. 65 p. Dissertação (Mestrado em Geografia) - Universidade de Brasília (UnB), Brasília, 2008. MATAVELI, G. A. V.; SILVA, M. E. S.; PEREIRA, G.; CARDOZO, F. S.; KAWAKUBO, F. S.; BERTANI, G.; COSTA, J. C.; RAMOS, R. de C.; SILVA, V. V. da. Satellite observations for describing fire patterns and climate-related fire drivers in the Brazilian savannas. **Natural Hazards and Earth System Sciences**, v. 18, n. 1, p. 125–144, 2018. DOI: <https://doi.org/10.5194/nhess-18-125-2018>.
- MCARTHUR, A.; CHENEY, N. The characterization of fires in relation to ecological studies. **Fire Ecology**, v. 11, n. 1, p. 3–9, 2015, DOI: <https://doi.org/10.1007/BF03400629>.
- MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**, v. 17, n. 7, p. 1425–1432, 1996.
- MILNE, A. Change direction analysis using Landsat imagery: a review of methodology. In: International Geoscience and Remote Sensing Symposium, “Remote Sensing: Moving Toward the 21st Century”, 1988, Edinburgh, UK. **Anais... Edinburgh, UK**, 1988, p. 541-544.
- MMA. Brazil’s Forest Reference Emission Level for Reducing Emissions from Deforestation in the Cerrado biome for Results-based Payments for REDD+ under the United Nations Framework Convention on Climate Change. [S.l.]: MMA, Brasília, Brazil, 2017.
- MYERS, N.; MITTERMEIER, R. A.; MITTERMEIER, C. G.; FONSECA, G. A. D.; KENT, J. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. 6772, p. 853-858, 2000. DOI: <https://doi.org/10.1038/35002501>.
- NEGRI, R. G.; LUZ, A. E.; FRERY, A. C.; CASACA, W. Mapping burned areas with multitemporal–multispectral data and probabilistic unsupervised learning. **Remote Sensing**, v. 14, n. 21, p. 5413, 2022, DOI: <https://doi.org/10.3390/rs14215413>.
- NUNES, B. Y. C.; SIMÕES, L. S.; AQUINO, G. S. de; ROSA, R.; REZENDE, P. S. Correção atmosférica de imagens do sensor WFI do CBERS-4 através do método dark object subtraction (DOS). In: Simpósio Brasileiro de Sensoriamento Remoto, 19, 2019, Santos. **Anais... São José dos Campos: INPE**, 2019. p. 935-938.
- OLDONI, L. **Harmonization of WFI data from the CBERS-4, CBERS-4A and AMAZONIA-1 satellites for agricultural applications**. 2022. 216 p. Tese (Doutorado em Sensoriamento Remoto) - Instituto

Nacional de Pesquisas Espaciais, São José dos Campos, Brasil, 2022.

- PASTOR, C. Q.; SHIMABUKURO, Y. E. Estimación de superficie quemada mediante la aplicación sinérgica de obia y sma a imágenes WFI CBERS. Simpósio Brasileiro de Sensoriamento Remoto, XIV, São José dos Campos, 2009. **Anais...** São José dos Campos, Brasil, 2009, p. 2119-2126.
- PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. Scikit-learn: machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825-2830, 2011. DOI: <https://doi.org/10.48550/arXiv.1201.0490>.
- PENHA, T. V. **Deteção de áreas queimadas na Amazônia utilizando imagens de média resolução espacial, técnicas de GEOBIA e mineração de dados**. 2018. 74 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, Brasil, 2018.
- PINTY, B.; VERSTRAETE, M. GEMI: a non-linear index to monitor global vegetation from satellites. **Vegetation**, v. 101, p. 15-20, 1992. DOI: <https://doi.org/10.1007/BF00031911>.
- PIVELLO, V. R.; VIEIRA, I.; CHRISTIANINI, A. V.; RIBEIRO, D. B.; MENEZES, L. da S.; BERLINCK, C. N.; MELO, F. P.; MARENGO, J. A.; TORNQUIST, C. G.; TOMAS, W. M.; OVERBECK, G. E. Understanding Brazil's catastrophic fires: Causes, consequences and policy needed to prevent future tragedies. **Perspectives in Ecology and Conservation**, v. 19, n. 3, p. 233-255, 2021, DOI: <https://www.perspectacolconserv.com/en-understanding-brazils-catastrophic-fires-causes-articulo-S2530064421000560>.
- RIBEIRO, A. F. S.; SANTOS, L.; RANDERSON, J. T.; URIBE, M. R.; ALENCAR, A. A. C.; MACEDO, M. N.; MORTON, D. C.; ZSCHEISCHLER, J.; SILVESTRINI, R. A.; RATTIS, L.; SENEVIRATNE, S. I.; BRANDO, P. M. The time since land-use transition drives changes in fire activity in the Amazon-Cerrado region. **Communications Earth & Environment**, v. 5, n. 96, 2024, DOI: <https://doi.org/10.1038/s43247-024-01248-3>.
- ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. **Monitoring vegetation systems in the great plains with ERTS**. Washington: NASA, 1974. 309 p. 14.
- RUSSO, G. M. Desenvolvimento de uma biblioteca Python para busca e processamento de dados do Satélite Sino-Brasileiro CBERS-04A. 51 p. Monografia (Graduação em Ciência da Computação) - Fundação Universidade Federal de Rondônia, Porto Velho, 2023.
- SCHEFFLER, D. AROSICS: An Automated and Robust Open-Source Image Co-Registration Software for multi-sensor satellite data. **Remote Sensing**, v. 9, n. 7, p. 676, 2017, DOI: <https://doi.org/10.3390/rs9070676>.
- SCHMIDT-ROHR, K. Why combustions are always exothermic, yielding about 418 kJ per mole of o₂. **Journal of Chemical Education**, v. 92, n. 12, p. 2094-2099, 2015, DOI: <https://doi.org/10.1021/acs.jchemed.5b00333>.
- SHIMABUKURO, Y. E.; DUTRA, A. C.; ARAI, E.; DUARTE, V.; CASSOL, H. L. G.; PEREIRA, G.; CARDOZO, F. S. Mapping burned areas of Mato Grosso State Brazilian Amazon using multisensor datasets. **Remote Sensing**, v. 12, n. 22, p. 3827, 2020, DOI: <https://doi.org/10.3390/rs12223827>.
- SIMON, M. F.; GREYER, R.; QUEIROZ, L. P. de; SKEMA, C.; PENNINGTON, R. T.; HUGHES, C. E. Recent assembly of the Cerrado, a neotropical plant diversity hotspot, by in situ evolution of adaptations to fire. **Proceedings of the National Academy of Sciences**, v. 106, n. 48, p. 20359-20364, 2009. DOI: <https://doi.org/10.1073/pnas.0903410106>.
- SILVA, W. K. L.; GRANDE, E. T. G.; OLIVEIRA, D. C. Estudo do satélite brasileiro Amazonia-1 e de sua trajetória: Mapeamento sistemático e análise documental dos artefatos históricos-oficiais. **Research, Society and Development**, v. 11, n. 2, p. 1-35, 2022, DOI: <https://doi.org/10.33448/rsd-v11i2.25894>.
- STROPPIANA, D.; BORDOGNA, G.; SALI, M.; BOSCHETTI, M.; SONA, G.; BRIVIO, P. A. A fully automatic, interpretable and adaptive machine learning approach to map burned area from remote

sensing, **ISPRS International Journal of Geo-Information**, v. 10, n. 8, p. 546, 2021, DOI: <https://doi.org/10.3390/ijgi10080546>.

SZPAKOWSKI, D. M.; JENSEN, J. L. A review of the applications of remote sensing in fire ecology. **Remote Sensing**, v. 11, n. 22, p. 2638, 2019, DOI: <https://doi.org/10.3390/rs11222638>.

TIWARI, T.; TIWARI, T.; TIWARI, S. How artificial intelligence, machine learning and deep learning are radically different?. **International Journal of Advanced Research in Computer Science and Software Engineering**, v. 8, n. 2, p. 1, 2018.

Biografia do autor principal



Alisson Cleiton de Oliveira nasceu em 1994 no município de Tatuí/SP. Recebeu o título de Bacharel em Gestão e Análise Ambiental pela Universidade Federal de São Carlos (UFSCar), em 2021, e o título de Mestre em Sensoriamento Remoto pelo Instituto Nacional de Pesquisas Espaciais (INPE), em 2024. Atualmente, é discente de doutorado do curso de Sensoriamento Remoto do INPE e reside em São José dos Campos/SP. Seus interesses de pesquisa incluem análise ambiental usando dados de sensoriamento remoto e aprendizado de máquina.



Esta obra está licenciada com uma Licença [Creative Commons Atribuição 4.0 Internacional](https://creativecommons.org/licenses/by/4.0/) – CC BY. Esta licença permite que outros distribuam, remixem, adaptem e criem a partir do seu trabalho, mesmo para fins comerciais, desde que lhe atribuam o devido crédito pela criação original.