



UNIVERSIDADE DE BRASÍLIA  
INSTITUTO DE CIÊNCIAS HUMANAS  
DEPARTAMENTO DE GEOGRAFIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

**INTEGRAÇÃO DE DADOS SAR E ÓPTICOS EM AMBIENTE DE  
COMPUTAÇÃO EM NUVEM PARA IDENTIFICAÇÃO DE FLORESTA  
ESTACIONAL DECIDUAL NO VÃO DO PARANÃ, GOIÁS**

Anderson Rodrigues Ribeiro

BRASÍLIA, 2026

**UNIVERSIDADE DE BRASÍLIA  
INSTITUTO DE CIÊNCIAS HUMANAS  
DEPARTAMENTO DE GEOGRAFIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA**

**Integração de dados SAR e ópticos em ambiente de computação  
em nuvem para identificação de Floresta Estacional Decidual no  
Vão do Paranã, Goiás**

Anderson Rodrigues Ribeiro

Orientador: Dr. Eder Renato Merino

Dissertação de mestrado submetida ao  
Programa de Pós-Graduação em  
Geografia da Universidade de Brasília  
como requisito para a obtenção do título de  
mestre em Geografia.

BRASÍLIA, 2026

## FICHA CATALOGRÁFICA

RIBEIRO, ANDERSON RODRIGUES

Integração de dados SAR e ópticos em ambiente de computação em nuvem para identificação de Floresta Estacional Decidual no Vão do Paranã, Goiás. 74 páginas.

Dissertação de mestrado – Departamento de Geografia, Instituto de Ciências Humanas - Universidade de Brasília – UnB, 2026.

1. Classificação – 2. Aprendizado de máquina – 3. Sensoriamento remoto – 4. Séries temporais – 5. Google Earth Engine

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação e emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta monografia pode ser reproduzida sem a autorização por escrito do autor.

---

Anderson Rodrigues Ribeiro

Junho de 2026

**UNIVERSIDADE DE BRASÍLIA  
INSTITUTO DE CIÊNCIAS HUMANAS  
DEPARTAMENTO DE GEOGRAFIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA**

**Integração de dados SAR e ópticos em ambiente de computação  
em nuvem para identificação de Floresta Estacional Decidual no  
Vão do Paranã, Goiás**

Anderson Rodrigues Ribeiro

Dissertação de mestrado submetida ao Programa de Pós-Graduação em Geografia da Universidade de Brasília como requisito para a obtenção do título de mestre em Geografia

Aprovado por:

---

Eder Renato Merino, Doutor (GEA-UNB)  
(Orientador)

---

Potira Meirelles Hermuche, Doutora (GEA-UNB)  
(Examinador interno)

---

Édipo Henrique Cremon, Doutor (INPE)  
(Examinador externo)

Brasília-DF, 22 de junho de 2026

## **AGRADECIMENTOS**

Agradeço ao Prof. Dr. Eder Renato Merino, pela orientação e apoio ao longo do desenvolvimento desta dissertação; ao LSIE (Laboratório de Sistemas de Informações Espaciais), do Departamento de Geografia da Universidade de Brasília, pelo suporte técnico e científico; aos meus familiares, amigos e colegas, pelo incentivo durante esta trajetória; e ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), referente ao edital de bolsa DPG-UnB nº 0018/2024, pelo apoio financeiro e fomento concedido para a realização desta pesquisa.

## SUMÁRIO

|                                                                                                                                                                                                                                                |    |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>1. INTRODUÇÃO</b>                                                                                                                                                                                                                           | 11 |
| <b>2. OBJETIVOS</b>                                                                                                                                                                                                                            | 16 |
| 2.1. Objetivo geral                                                                                                                                                                                                                            | 16 |
| 2.2. Objetivos específicos                                                                                                                                                                                                                     | 16 |
| <b>3. REVISÃO SISTEMÁTICA DE LITERATURA</b>                                                                                                                                                                                                    | 17 |
| 3.1. Artigo de Revisão publicado na Revista Brasileira de Cartografia, intitulado “Revisão Sistemática de Literatura sobre o uso de Sensoriamento Remoto e Algoritmos baseados em Machine Learning no mapeamento de Florestas Tropicais Secas” | 17 |
| <b>4. CARACTERIZAÇÃO REGIONAL</b>                                                                                                                                                                                                              | 33 |
| <b>5. MÉTODOS</b>                                                                                                                                                                                                                              | 36 |
| 5.1. Área de estudo                                                                                                                                                                                                                            | 36 |
| 5.2. Dados de sensoriamento remoto utilizados                                                                                                                                                                                                  | 36 |
| 5.3. Processamento dos dados                                                                                                                                                                                                                   | 37 |
| 5.3.1. Dados climáticos                                                                                                                                                                                                                        | 38 |
| 5.3.2. Processamento dos dados SAR                                                                                                                                                                                                             | 39 |
| 5.3.3. Processamento dos dados ópticos                                                                                                                                                                                                         | 39 |
| 5.3.4. Processamento dos dados de elevação                                                                                                                                                                                                     | 40 |
| 5.3.5. Elaboração dos conjuntos de dados para classificação                                                                                                                                                                                    | 40 |
| 5.4. Amostragem                                                                                                                                                                                                                                | 42 |
| 5.5. Classificação e avaliação                                                                                                                                                                                                                 | 43 |
| <b>6. RESULTADOS</b>                                                                                                                                                                                                                           | 45 |
| 6.1. Resultados gerais das classificações                                                                                                                                                                                                      | 45 |
| 6.2. Resultados das classificações agrupadas por classe                                                                                                                                                                                        | 48 |
| 6.3. Variáveis mais importantes nos modelos de classificação                                                                                                                                                                                   | 56 |
| <b>7. DISCUSSÃO</b>                                                                                                                                                                                                                            | 59 |
| 7.1. Integração de dados SAR e ópticos                                                                                                                                                                                                         | 59 |
| 7.2. Desempenho dos algoritmos de classificação e variáveis preditoras                                                                                                                                                                         | 60 |
| 7.3. Limitações da abordagem desenvolvida e perspectivas futuras                                                                                                                                                                               | 64 |
| <b>8. CONSIDERAÇÕES FINAIS</b>                                                                                                                                                                                                                 | 66 |
| <b>9. REFERÊNCIAS</b>                                                                                                                                                                                                                          | 67 |

## LISTA DE FIGURAS

|                                                                                                                                                                                      |    |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Figura 1</b> - Localização do Vão do Paranã, com destaque para variação da resposta espectral nas estações seca (A) e úmida (B) em imagens Sentinel-2 RGB 4-3-2 (cor verdadeira). | 12 |
| <b>Figura 2</b> - Climograma com dados de precipitação referentes a janeiro de 1984 a dezembro de 2024 e temperatura de janeiro de 2000 a dezembro de 2024.                          | 34 |
| <b>Figura 3</b> – Contexto ambiental regional.                                                                                                                                       | 35 |
| <b>Figura 4</b> - Localização da área de estudo, com layout principal (A) apresentando imagem Sentinel-2, com composição RGB 8-4-3.                                                  | 36 |
| <b>Figura 5</b> - Fluxograma do processamento na plataforma GEE.                                                                                                                     | 38 |
| <b>Figura 6</b> - Pontos amostrais coletados e variação altimétrica da área de estudo.                                                                                               | 42 |
| <b>Figura 6</b> - Interpretação dos níveis de acurácia.                                                                                                                              | 44 |
| <b>Figura 7</b> - Mapa matricial da avaliação geral dos modelos de classificação.                                                                                                    | 46 |
| <b>Figura 8</b> - Ranqueamento dos modelos de classificação que alcançaram as 10 maiores AGs.                                                                                        | 47 |
| <b>Figura 9</b> - Comparação de resultados gerais entre o RF e GTB para as combinações temporais.                                                                                    | 47 |
| <b>Figura 10</b> - Layouts das classificações dos conjuntos de dados SAR.                                                                                                            | 49 |
| <b>Figura 11</b> - Avaliação das classes mapeadas nos modelos SAR.                                                                                                                   | 50 |
| <b>Figura 12</b> - Layouts das classificações dos conjuntos de dados ópticos.                                                                                                        | 52 |
| <b>Figura 13</b> - Avaliação das classes mapeadas nos modelos ópticos.                                                                                                               | 53 |
| <b>Figura 14</b> - Layouts das classificações dos modelos SAR e ópticos integrados.                                                                                                  | 54 |
| <b>Figura 15</b> - Avaliação das classes mapeadas nos modelos SAR e ópticos integrados.                                                                                              | 55 |
| <b>Figura 16</b> - Ranqueamento das cinco variáveis mais importantes nos modelos de classificação RF.                                                                                | 56 |
| <b>Figura 17</b> - Ranqueamento das cinco variáveis mais importantes nos modelos de classificação GTB.                                                                               | 57 |

## LISTA DE TABELA

|                                                                     |    |
|---------------------------------------------------------------------|----|
| <b>Tabela 1</b> - Conjuntos de dados elaborados para classificação. | 41 |
|---------------------------------------------------------------------|----|

## LISTA DE QUADROS

|                                                                                                                                                          |    |
|----------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Quadro 1</b> - Dados de sensoriamento utilizados na pesquisa e respectiva aplicação.                                                                  | 37 |
| <b>Quadro 2</b> - Classes utilizadas na amostragem, descrição e produto de cobertura da terra utilizado como referência para coleta de pontos amostrais. | 43 |

## RESUMO

As Florestas Estacionais Deciduais do bioma Cerrado desempenham papel fundamental na conservação da biodiversidade e na provisão de serviços ecossistêmicos, tornando seu mapeamento acurado essencial para subsidiar estratégias de conservação. Entretanto, a marcada sazonalidade dessa fitofisionomia impõe desafios à sua identificação por sensoriamento remoto, especialmente em abordagens baseadas exclusivamente na classificação de dados ópticos, devido à semelhança na resposta espectral com outras classes de vegetação. Nesse contexto, esta pesquisa propôs uma avaliação abrangente combinando uma revisão sistemática da literatura sobre a aplicação de algoritmos de *Machine Learning* e dados de sensoriamento remoto em estudos sobre as Florestas Estacionais Deciduais, com uma abordagem empírica baseada na integração de dados SAR (*Synthetic Aperture Radar*) e ópticos e na análise comparativa do desempenho dos classificadores Random Forest e Gradient Tree Boost em ambiente de computação em nuvem, visando identificar o melhor cenário para o mapeamento dessa fitofisionomia na ecorregião do Vão do Paranã, reconhecida por abrigar os maiores remanescentes de Floresta Estacional do Cerrado. Os resultados evidenciaram desempenho superior do algoritmo Gradient Tree Boost associado à integração de dados SAR e ópticos, destacando a elevação como a variável preditora de maior importância em todos os modelos avaliados. Esses achados reforçam o potencial da integração de múltiplas fontes de dados e algoritmos avançados para o aprimoramento do mapeamento de Florestas Estacionais Deciduais. Pesquisas futuras podem buscar avaliar a abordagem desenvolvida na presente pesquisa em outras áreas de estudo, com ênfase na incorporação de outros fatores ambientais como atributos variáveis preditoras em novos modelos de classificação.

**Palavras-chave:** classificação, aprendizado de máquina, sensoriamento remoto, séries temporais, google earth engine.

## ABSTRACT

Tropical Dry Forests within the Cerrado biome play a fundamental role in biodiversity conservation and the provision of ecosystem services, making their accurate mapping essential to support conservation strategies. However, the marked seasonality of this physiognomy poses challenges for its identification through remote sensing, particularly in approaches based exclusively on the classification of optical data, due to the similarity in spectral response with other vegetation classes. In this context, this research proposed a comprehensive assessment combining a systematic literature review on the application of Machine Learning algorithms and remote sensing data in studies of Tropical Dry Forests, with an empirical approach based on the integration of SAR (Synthetic Aperture Radar) and optical data and the comparative analysis of the performance of the Random Forest and Gradient Tree Boost classifiers in a cloud computing environment, aiming to identify the best scenario for mapping this physiognomy in the Vão do Paranã ecoregion, recognized for harboring the largest remnants of Tropical Dry Forests in the Cerrado. The results demonstrated superior performance of the Gradient Tree Boost algorithm associated with the integration of SAR and optical data, highlighting elevation as the most important predictive variable in all evaluated classification models. These findings reinforce the potential of integrating multiple data sources and advanced algorithms to improve the mapping of Tropical Dry Forests. Future research may seek to evaluate the approach developed in this study in other study areas, with emphasis on incorporating additional environmental factors as predictive variables in new classification models.

**Key words:** classification, machine learning, remote sensing, time series, google earth engine.

## 1. INTRODUÇÃO


A Floresta Tropical Seca (*Tropical Dry Forest*, na nomenclatura internacional) ou Floresta Estacional Decidua (FED), conforme é conhecida no Brasil, ocorre em diversos biomas da zona tropical, de tal modo que é reconhecida como um ecossistema global (Ganem et al., 2022). De modo geral, a FED pode ser definida como formações arbóreas que ocorrem em regiões de climas com duas estações bem definidas (úmida e seca), e com a vegetação apresentando acentuada deciduidade (ao menos 50% de perda de folhas) ao longo da estação seca (Ribeiro; Walter, 2008). Além disso, tais formações podem apresentar temperatura anual média de 25 °C e precipitação anual média variando entre 700 e 2000 mm, com pelo menos 3 ou mais meses secos (precipitação  $\leq 100$  mm/mês) por ano (Espírito-Santo et al., 2006). Tais ecossistemas abrigam grande variedade de fauna e flora, de maneira que desempenham um papel fundamental na conservação da biodiversidade e fornecimento de abrigo e comida para comunidades locais (Gao et al., 2023), bem como a provisão de variados serviços ecossistêmicos (Calvo-Rodriguez et al., 2017, Smith et al., 2019).

A FED pode ser encontrada em diferentes biomas brasileiros, sendo o Cerrado e Caatinga (onde é conhecida como caatinga arbórea) os ambientes em que ocorrem em maior extensão (Coelho; Fernandes; Sanchez-Azofeifa, 2013). No contexto do bioma Cerrado, além da FED, as Matas Ciliares ou de Galeria e Cerradão são classificadas como fitofisionomias florestais (Ribeiro; Walter, 2008, Santos; Miranda; Silva Neto, 2020). Além disso, dentre as formações florestais do Cerrado, a FED e o Cerradão destacam-se por serem as únicas fitofisionomias desse bioma que ocorrem de maneira não associada a cursos de drenagem, sendo que a FED apresenta a peculiaridade da ocorrência de deciduidade em diferentes níveis durante estação seca, o que, em determinados contextos, torna difícil o seu mapeamento acurado em imagens de sensoriamento remoto (SR) (Araújo; Galvão; Dalagnol, 2023, Hermuche; Sano, 2011).

No Cerrado, a FED ocorre notadamente na ecorregião Vão do Paranã (Ribeiro; Walter, 2008) (Figura 1), na forma de disjunções ou fragmentos naturais, coincidindo com áreas de solos bem drenados de média a alta fertilidade (Pereira; Venturoli; Carvalho, 2011). Tais características de solo são consideradas como favoráveis à prática de agricultura (Pennington; Prado; Pendry, 2000), de modo que esta constitui

umas das principais ameaças à conservação desse ecossistema, bem como a pecuária e mineração de calcário (Coelho; Fernandes; Sanchez-Azofeifa, 2013, Hermuche; Ferreira; Sano, 2009). Além disso, destacam-se processos como o de escassez hídrica, estiagem, desertificação e mudanças na cobertura da terra, associadas aos impactos da mudança climática, como fatores que podem causar alterações significativas na segurança alimentar e bem-estar das populações que vivem em regiões de FED (Farrick; Branfireun, 2013; Schroder; Rodríguez; Gunter, 2021).

**Figura 1** - Localização do Vão do Paranã, com destaque para variação da resposta espectral nas estações seca (A) e úmida (B) em imagens Sentinel-2 RGB 4-3-2 (cor verdadeira).



Fonte: elaboração própria.

Considerando as características das ameaças associadas às áreas de FED, ações de monitoramento ambiental são fundamentais à formulação de estratégias de conservação. Nesse sentido, destaca-se o SR como ferramenta tecnológica de alto impacto no monitoramento ambiental de vegetação, sobretudo das florestas tropicais secas, devido a sua capacidade de aquisição de informações sistemáticas de modo

regular sobre processos que ocorrem na superfície terrestre (Carvalho Júnior, 2018; Hesketh e Sanchez-Azofeifa, 2013).

O domínio dos dados de SR pode ser dividido entre sensores ativos, o que inclui tecnologias como SAR (*Synthetic Aperture Radar*) e LiDAR (*Light Detection and Ranging*), e passivos, os quais abarcam os sensores ópticos multiespectrais e hiperespectrais (Lechner, Foody; Boyd, 2020), a exemplo da série Landsat e Sentinel-2. Sensores ópticos necessitam da disponibilidade de energia solar refletida para capturar imagens da superfície terrestre, o que os deixam sujeitos a presença de ruídos nas imagens capturadas, tais como nuvens, sombras e neblina (Agrawal; Khairnar, 2019; Ferla; Kuplich; Narvaes, 2025; Ribeiro; Merino, 2025). Desse modo, como alternativa, tem sido proposta por diversos pesquisadores a utilização de dados provenientes de sensores ativos, a exemplo das imagens SAR, como aquelas geradas pelo satélite Sentinel-1, uma vez que o sistema de imageamento destes sensores operam a partir da mensuração do retroespalhamento do pulso emitido pelo sensor, de modo que as imagens capturadas por essa tecnologia não dependem (ou são muito poucos afetadas) pelas condições atmosféricas (Sirro et al., 2018). Além disso, dados de SR ópticos caracterizam-se por informações referentes às características físico-químicas dos objetos, ao passo que os dados SAR permitem a obtenção de informações estruturais, volumétricas e propriedades dielétricas dos alvos (Ferla; Kuplich; Narvaes, 2025).

Por conseguinte, dados de SR podem ser utilizados para caracterizar diferentes atributos de áreas de FED, a exemplo da identificação da sua extensão territorial e diferenciação entre demais formações florestais (Alba et al., 2022; Guimarães et al., 2006), bem como estimativas de biomassa, índice de área basal, diversidade de espécies, além do mapeamento da deciduidade em grande escala geográfica e em intervalos temporais regulares (Huechacona-Ruiz et al., 2020).

Segundo Oliveira et al. (2020), há consenso na literatura de que o mapeamento da vegetação do Cerrado em um primeiro nível hierárquico, com classes amplas como formações florestais, savânicas e campestres, alcança cerca de 90% de exatidão. Contudo, o desafio persiste no segundo nível hierárquico, que envolve a discriminação de diferentes tipos fitofisionômicos, como distinguir FED de Cerradão em imagens de SR, ainda sem atingir níveis de exatidão semelhantes.

Outro desafio no mapeamento de formações florestais em ambientes savânicos é a identificação do melhor período de aquisição das imagens de SR para identificação

de diferentes classes de cobertura vegetal em ambientes tropicais (Gyamfi-Ampadu; Gebreslasie; Mendoza-Ponce, 2020). Nesse contexto, linhas de investigação têm sido propostas para a determinação do melhor período para obtenção de mapas de vegetação em ambientes savânicos (Higginbottom et al., 2018; Symeonakis et al., 2018).

Estudos de SR prévios sobre a FED no Vão do Paranã, como o de Carvalho Júnior; Guimarães e Hermuche (2006), investigaram a utilização de séries temporais de NDVI (*Normalized Difference Vegetation Index*) do sensor MODIS para identificar essa fitofisionomia. Já Hermuche e Sano (2011), investigaram a identificação da FED por meio da técnica de análise de reflectância acumulada em imagens Landsat 5/TM. Bendini et al. (2022) buscaram avaliar a separabilidade entre as fitofisionomias FED e Cerradão utilizando séries densas de dados Landsat 7/TM e os classificadores de domínio da Inteligência Artificial Random Forest (RF) e Long Short-Term Memory (LSTM).

Programas de monitoramento recentes, tais como o Projeto Map Biomas (MAPBIOMAS, 2025), têm fornecido mapas multitemporais de uso e cobertura da terra para o Brasil advindos do processamento de dados das coleções Landsat, com 30 m de resolução espacial, no entanto, ainda não conseguiram definir uma metodologia para identificação de fitofisionomias como a FED ou Cerradão. Ademais, programas de monitoramento globais como MODIS Land Cover (Friedl; Sulla-Menashe, 2022) identificam áreas de FED, no entanto, o fazem com resolução espacial de 500 m, o que torna inviável a utilização desses dados em análises em escala local, o que indica a necessidade de estudos para obtenção de mapas com maior acurácia da distribuição da FED, tal como os dados Sentinel-2, com resolução de 10 a 20 m (Chaves; Picoli; Sanches, 2020; Oliveira et al., 2020).

Estudos recentes têm destacado a importância da ferramenta de computação em nuvem Google Earth Engine (GEE) (Gorelick et al., 2017), a qual se consolidou em pesquisas na área do SR, uma vez dispõe de um amplo catálogo de dados, bem como diversas funcionalidades, a exemplo da aquisição e processamento de grandes volumes de dados para extração de informações da superfície terrestre a partir do agrupamento de séries de imagens em composições sazonais (Tsai et al., 2018) e anuais (Phan; Kuch; Lehnert, 2020), comumente aplicados em estudos de classificação de uso e cobertura da terra (Becker et al., 2021; Savitha; Talari, 2025; Silva et al., 2021). Nesse contexto, a presente pesquisa insere-se na perspectiva de

avaliar o potencial dessas abordagens integradas, com ênfase na comparação entre diferentes estratégias de classificação e uso de dados, visando aprimorar o mapeamento de FEDs que ocorrem no Vão do Paranã.

## 2. OBJETIVOS

### 2.1. Objetivo geral

Esta pesquisa tem como objetivo geral avaliar comparativamente o desempenho de métodos de classificação baseados nos algoritmos Random Forest (RF) e Gradient Tree Boost (GTB), aplicados a dados SAR do Sentinel-1 e ópticos multiespectrais do Sentinel-2, processados na ferramenta de computação em nuvem GEE, para a identificação de FEDs na ecorregião Vão do Paranã.

### 2.2. Objetivos específicos

Os objetivos específicos desta pesquisa incluem:

- a) Obter o estado da arte do uso de classificadores de abordagem ML e dados de SR aplicados às áreas de FED, por meio de uma revisão sistemática de literatura.
- b) Identificar qual combinação temporal dos dados SAR e ópticos fornecem os melhores resultados de classificação.
- c) Analisar comparativamente o desempenho dos classificadores RF e GTB para a separabilidade entre FED e Cerradão.
- d) Identificar quais variáveis possuem maior importância relativa nos modelos de classificação.

### 3. REVISÃO SISTEMÁTICA DE LITERATURA

3.1. Artigo de Revisão publicado na Revista Brasileira de Cartografia, intitulado “Revisão Sistemática de Literatura sobre o uso de Sensoriamento Remoto e Algoritmos baseados em *Machine Learning* no mapeamento de Florestas Tropicais Secas”

#### INTRODUÇÃO

As florestas tropicais secas ocorrem em diversos biomas da zona tropical, de tal modo que são consideradas um ecossistema global (Ganem et al., 2020). Essas florestas cobrem aproximadamente de 1.047.000 km<sup>2</sup> da superfície terrestre, sendo 66% dessa área localizada no continente americano (Hesketh & Sanchez-Azofeifa, 2014). Considerando a distribuição espacial pela faixa tropical da superfície terrestre, estas florestas também ocorrem na Ásia (16%), África (13,1%) e em fragmentos na Oceania (3,8%) (Farrick & Branfireun, 2013), podendo apresentar temperatura média anual maior que 26 °C e precipitação anual variando de 250 a 2.000 mm (Huechacona-Ruiz et al., 2020). Outras definições importantes acerca desse ecossistema se dão pela caracterização como formações florestais que ocorrem em regiões tropicais, sendo notadamente marcadas pela sazonalidade da distribuição das chuvas (Miles et al., 2006; Schroder et al., 2021). Além disso, são compostas por espécies que apresentam alta deciduidade nos períodos secos e grande perenidade nos períodos chuvosos (Hermuche & Sano, 2011), sendo que os períodos de seca podem durar entre 3 e 7 meses (Farrick & Branfireun, 2013), com precipitação média mensal menor que 100 mm (Huechacona-Ruiz et al., 2020).

As florestas tropicais secas abrigam uma grande variedade de fauna e flora, desempenhando um importante papel na conservação da biodiversidade e fornecimento de abrigo e comida para comunidades locais (Gao et al., 2023), além de diversos outros serviços ecossistêmicos (Smith et al., 2019). Além disso, ocorrem em solos férteis com pH e status de nutrientes variando de moderados a altos, com baixos níveis de alumínio. Tais características de solo são consideradas como favoráveis à prática de agricultura (Pennington et al., 2000), de modo que esta constitui umas das principais ameaças à conservação de florestas tropicais secas. Além do fator mencionado anteriormente, processos como o de escassez hídrica, estiagem, desertificação e mudanças na cobertura da terra, associadas aos impactos da mudança climática, podem causar alterações significativas na segurança alimentar e bem-estar das populações que vivem em regiões de florestas tropicais secas (Farrick & Branfireun, 2013; Schroder et al., 2021).

Dadas as características das ameaças inerentes às áreas de floresta tropical seca, ações de monitoramento ambiental são fundamentais à formulação de estratégias de conservação. Nesse sentido, destaca-se o sensoriamento remoto (SR) como ferramenta tecnológica de alto impacto no monitoramento ambiental de vegetação, sobretudo das florestas tropicais secas, devido a sua capacidade de aquisição de informações sistemáticas, sinóticas e com baixos custos (Carvalho Júnior, 2018; Hesketh & Sanchez-Azofeifa, 2014).

O domínio do SR pode ser dividido entre sensores ativos e passivos. Os sensores passivos subdividem-se em sensores multiespectrais e hiperespectrais (Shafri, 2017). Os sensores multiespectrais possuem um número limitado de bandas, enquanto os sensores hiperespectrais podem ser compostos por algumas centenas de bandas muito mais estreitas, em termos espectrais (Lechner et al., 2020). Como limitação, sensores ópticos necessitam da disponibilidade de energia solar refletida da superfície terrestre para realizar o imageamento (Agrawal & Khairnar, 2019). Os sensores ativos incluem sistemas de detecção por LiDAR (*Light Detection and Ranging*) e SAR (*Synthetic Aperture Radar*). Esses sensores emitem um pulso e medem o retroespalhamento refletido de volta para o sensor. Uma vantagem

fundamental desses sensores é sua capacidade de penetrar obstáculos como nuvens e fumaça, além de operar à noite. Os sensores SAR podem diferenciar características de cobertura de terra de acordo com sua rugosidade de superfície, estrutura tridimensional dos alvos e umidade (Lechner et al., 2020).

Dados de SR possuem potencial para caracterizar diferentes atributos das florestas tropicais secas, a exemplo de estimativas de biomassa, índice de área basal, diversidade de espécies, bem como o mapeamento da deciduidade em grande escala geográfica e em frequentes intervalos temporais (Huechacona-Ruiz et al., 2020). Neste sentido, a utilização de informações ambientais derivadas de dados de SR tem sido cada vez mais utilizadas em sistemas de apoio para definição de políticas públicas para o monitoramento ambiental e sistema de alertas de desastres nas mais diversas escalas (Carvalho Júnior, 2018).

Recentemente, a integração de técnicas de *Machine Learning* (ML) e dados de SR para mapeamento e mensuração de atributos da vegetação tem ganhado significativa atenção da comunidade científica (Talukdar et al., 2020; Singh et al., 2022). As técnicas de ML (conhecidas como métodos não paramétricos) apresentam vantagens em relação aos métodos tradicionais (métodos paramétricos), pois são capazes de avaliar dinâmicas não-lineares complexas entre a reflectância captada pelos sensores remotos e a estrutura da vegetação, sem realizar nenhuma acepção prévia acerca da distribuição dos dados (Singh et al., 2022). Além disso, essas técnicas também são adequadas para aplicação em dados complexos ou abordagens que utilizam conjuntos de dados fusionados (Shafri, 2017), de modo que apresentam em um grande potencial para aplicações em ecossistemas terrestres, uma vez que o desenvolvimento da vegetação varia espaço-temporalmente devido a diversos fatores como a diversidade geológica, climática, desmatamento e queimadas (Singh et al., 2022).

Algumas contribuições de grande relevância têm sido publicadas na literatura científica sobre florestas tropicais secas. Alguns exemplos podem ser destacados, como o de Bendini et al. (2022), em que utilizaram os algoritmos de classificação supervisionada *Random Forest* (RF) e *Long Short Term Memory* (LSTM) aplicados a séries temporais densas de dados multiespectrais dos sensores Landsat 7/ETM+ e Landsat 8/OLI para verificar a capacidade desses algoritmos de separar florestas tropicais secas da fitofisionomia cerradão, no estado brasileiro do Tocantins, atingindo excelentes acurácias de mapeamento. Já Li et al. (2017), utilizaram o classificador *Multi-task Learning Based Machine-learning Classifier* (MLC-MTC) em uma abordagem de integração de dados LiDAR com dados ópticos hiperespectrais, para classificar estágios sucessionais em uma floresta tropical seca na Costa Rica. Além disso, também destaca-se a contribuição de Singh et al., (2022), em que realizaram uma análise comparativa entre algoritmos não paramétricos e semi-paramétricos para estimar a biomassa acima do solo com dados multiespectrais Sentinel-2/MSI em uma floresta tropical seca na Índia.

À medida que novos estudos de aplicações de ML em dados de SR de florestas tropicais secas são desenvolvidos, surge a necessidade de estudos que apresentam uma revisão abrangente das investigações realizadas, a fim de compreender os padrões de investigação nesta área. Neste sentido destacam-se as Revisões Sistemáticas de Literatura (RSL) como um método para descrição, sintetização e avaliação, de modo organizado e estruturado, da produção científica sobre um determinado tema (Azevedo et al., 2023), de tal modo que este tem se tornado um método de pesquisa cada vez mais recorrente nas geociências (Herrmann et al., 2022).

Considerando a variedade de abordagens e o crescente interesse de aplicações de técnicas ML em dados de SR para investigação de florestas tropicais secas, o objetivo do presente estudo é identificar, por meio de uma Revisão Sistemática de Literatura, quais têm sido os principais métodos de ML utilizados em dados provenientes de SR nos últimos anos, em pesquisas sobre florestas tropicais secas, de modo a apontar uma visão geral das principais tendências e oportunidades neste campo de pesquisa. Além disso, cabe salientar que como subdomínio do ML, o *Deep Learning* (DL) tem sido apontado como o estado da arte das técnicas de classificação de imagens de SR (Klompenburg et al., 2020), no entanto estes métodos ainda não foram amplamente adotados (Maxwell et al., 2018) ou implementados

em *softwares* de processamento de imagens de SR convencionais. Por essa razão, esta revisão priorizou a análise de métodos de ML amplamente adotados e testados na literatura acerca do tema. Acrescenta-se que esta revisão fornecerá informações para gestores florestais, geógrafos, ecologistas e especialistas em SR sobre os avanços feitos e as deficiências observadas em relação ao uso de algoritmos de ML e imagens de SR para monitoramento de florestas secas em zonas tropicais.

## MÉTODOS

O método selecionado para a realização desta pesquisa foi o de Revisão Sistemática de Literatura (RSL). A RSL trata-se de um método de pesquisa que utiliza como fonte de dados a literatura acerca de um determinado tema (Sampaio & Mancini, 2007). Considerando que em uma RSL é recomendado que se elabore um protocolo de pesquisa que inclua, além do objetivo norteador da pesquisa, itens que expliquem como os estudos foram encontrados e critérios de inclusão e exclusão dos trabalhos (Lycarião et al., 2023). Neste sentido, o protocolo seguido nesta pesquisa é listado a seguir: a) definição das questões de pesquisa; b) seleção das bases de dados; c) definição dos termos de busca; e d) definição de critérios de inclusão e exclusão.


Duas questões de pesquisa norteadoras foram definidas para avaliação dos artigos selecionados para a revisão, de modo que buscou-se analisar quantitativamente: 1) quais dados de SR estão sendo mais utilizados e 2) quais algoritmos de ML estão sendo mais utilizados para análise e mapeamento de florestas secas, considerando o intervalo temporal de 2014 e 2024, assim, obtendo-se uma visão geral das principais aplicações no contexto da última década.

A base de dados prioritária para a seleção dos artigos científicos desta RSL foi a base *Web of Science* (WoS), acessada por meio do Portal de Periódicos CAPES (CAPES, 2024). No entanto, buscas em bases alternativas como o *Google Scholar*, e até mesmo as referências dos artigos recuperados pela base WoS foram checadas, com intuito de reter a maior quantidade possível de artigos relevantes relacionados com a temática desta pesquisa.

Como termos de busca foram utilizados *Tropical Dry Forest*, *Classification*, *Remote Sensing* e *Machine Learning*, tendo sido testadas buscas com diferentes estratégias de combinações com os operadores booleanos *AND* e *OR*. Considerando a vasta extensão das florestas tropicais secas pela América Latina, artigos em língua portuguesa e espanhola também foram considerados nesta revisão, bem como artigos de congressos internacionais, como ISPRS (*International Society for Photogrammetry and Remote Sensing*) e o *Environmental Sciences Proceedings*.

Após a realização das buscas nas bases de dados, os artigos em potencial para revisão foram submetidos à verificação dos critérios de filtragem a fim de se chegar à lista final de artigos a serem revisados. A verificação consistiu na leitura dos títulos, resumos e palavras-chave. Posteriormente, as palavras-chave dos artigos selecionados para a revisão foram utilizadas para construção de uma rede coocorrência, com ao menos 3 palavras-chave, com o propósito de identificar outros temas emergentes associados à temática principal desta revisão. Para este procedimento foi utilizada a ferramenta de análise bibliométrica VOSViewer, na versão 1.6.20. Ao final, após a extração correta de todos os dados necessários, os dados foram sintetizados em quadros explicativos e imagens-síntese, de modo a fornecer uma visão geral dos resultados das questões de pesquisa investigadas. O fluxo metodológico seguido nesta revisão pode ser visualizado na Figura 1.

Figura 1 – Fluxo metodológico da revisão.



Fonte: Os autores (2024).

## RESULTADOS

A busca sistemática retornou 207 publicações da base de dados WoS e, como resultado do processo de filtragem, 12 artigos atenderam aos critérios de seleção e foram incluídos para análise. Após busca complementar na base *Google Scholar* e verificação das referências bibliográficas dos primeiros artigos selecionados, outros 9 artigos foram incluídos qualitativamente para compor a lista final de 21 artigos selecionados para revisão sistemática (Quadro 1). Observou-se que a maior parte das publicações foram concentradas entre 2020 e 2022, tendo sido este, o período verificado como o de maior pico de publicações.


A partir da Figura 2 é possível observar que a região Neotropical tem tido grande destaque na quantidade de áreas estudadas, sendo Brasil e México os países que possuem mais áreas de estudo investigando florestas tropicais secas por métodos de ML baseado em SR, conforme os critérios adotados para a seleção sistemática dos artigos da revisão.

Quadro 1 – Artigos científicos selecionados para a revisão.

| ID | Autor(es)                       | Ano de Publicação | Título da Publicação                                                                                                                                                                             |
|----|---------------------------------|-------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| 1  | Wohlfart et al.                 | 2014              | <i>Mapping threatened dry deciduous dipterocarp forest in South east asia for conservation management</i>                                                                                        |
| 2  | Abade et al.                    | 2015              | <i>Comparative analysis of MODIS Time-Series Classification Using Support Vector Machines and Methods Based upon Distance and Similarity Measures in the Brazilian Cerrado-Caatinga Boundary</i> |
| 3  | Millan et al.                   | 2015              | <i>Mapping tropical dry forest succession with CHRIS/PROBA hyperspectral images using nonparametric decision trees</i>                                                                           |
| 4  | Li et al.                       | 2017              | <i>Identifying tropical dry forests extent and succession via the use machine learning techniques</i>                                                                                            |
| 5  | Vargas-Sanabria e Campos-Vargas | 2018              | <i>Sistema multi-algoritmo para la clasificación de coberturas de la tierra en el bosque seco tropical de Área de Conservación Guanacaste, Costa Rica</i>                                        |
| 6  | Millan e Sanchez-Azofeifa       | 2018              | <i>Quantifying Changes on Forests Succession in a Dry Tropical Forest Using Angular-Hyperspectral Remote Sensing</i>                                                                             |
| 7  | Shimizu et al.                  | 2019              | <i>Detecting Forest Changes Using Dense Landsat 8 and Sentinel-1 Time Series Data in Tropical Seasonal Forests</i>                                                                               |
| 8  | Rocha et al.                    | 2020              | <i>Monitoramento da Floresta Estacional Brasileira por Sensoriamento Remoto</i>                                                                                                                  |
| 9  | Hernandez-Stefanoni et al.      | 2020              | <i>Improving aboveground biomass maps of tropical dry forests by integrating LiDAR, ALOS PALSAR, climate and field data</i>                                                                      |
| 10 | Huechacona-Ruiz et al.          | 2020              | <i>Mapping tree species deciduousness of tropical dry forests combining reflectance, spectral unmixing, and texture data from high-resolution imagery</i>                                        |
| 11 | Cardoso et al.                  | 2021              | <i>Mapeamento de áreas de Caatinga através do Random Forest: estudo de caso na bacia do rio Taperoá</i>                                                                                          |
| 12 | Reyes-Palomeque et al.          | 2021              | <i>Mapping forest age and characterizing vegetation structure and species composition in tropical dry forests</i>                                                                                |
| 13 | Andres-Mauricio et al.          | 2021              | <i>Mapping structural attributes of tropical dry forests by combining Synthetic Aperture Radar and high-resolution satellite imagery data</i>                                                    |
| 14 | Alba et al.                     | 2022              | <i>Comparação entre Algoritmos de Aprendizado de Máquina para a Identificação de Floresta Tropical Sazonalmente Seca</i>                                                                         |
| 15 | Vizzari                         | 2022              | <i>PlanetScope, Sentinel-2, Sentinel-1 Data Integration for object-based Land cover Classification in Google Earth Engine</i>                                                                    |
| 16 | Barboza et al.                  | 2022              | <i>Cover and Land Use Changes in the Dry Forest of Timbes (Peru) Using Sentinel-2 and Google Earth Engine</i>                                                                                    |
| 17 | Bendini et al.                  | 2022              | <i>Evaluating the separability of between dry tropical forests and savanna woodlands in the brazilian savanna using Landsat dense time series and artificial intelligence</i>                    |
| 18 | Verheggen et al.                | 2022              | <i>Mapping Canopy cover in African Dry Forests from the combined use of sentinel-1 and sentinel-2: application to Tanzania for the year 2018</i>                                                 |
| 19 | Singh et al.                    | 2022              | <i>Remote sensing-based biomass estimation of dry deciduous tropical forest using machine learning and ensemble analysis</i>                                                                     |
| 20 | Gao et al.                      | 2023              | <i>Tropical Dry Forests Dynamics Explained by Topographic and Anthropogenic Factors: A Case Study in Mexico</i>                                                                                  |
| 21 | Sesnie et al.                   | 2023              | <i>Ensemble Machine Learning for Mapping Tree Species Alfa-Diversity Using Multi-Source Satellite Data in a Ecuadorian Seasonally Dry Forest</i>                                                 |

Elaboração: Os autores (2024).


Figura 2 – Países em que as áreas de estudo foram identificadas nas publicações.



Fonte: Os autores (2024).


Na Figura 3 é possível observar o agrupamento de palavras-chave com pelo menos 3 ocorrências nos artigos revisados, enquanto na Figura 4 são apresentados os agrupamentos conforme o ano de publicação dos termos. Como temas emergentes associados às publicações revisadas estão incluídas análises de acurácia (*accuracy*) e distribuição espacial (*spatial distribution*) identificadas no agrupamento em azul, topografia (*topography*) e biodiversidade (*biodiversity*) em vermelho, e mudança climática (*climate change*) e dosséis (*canopies*) no agrupamento em verde.

Figura 3 - Agrupamentos da rede de coocorrência de palavras-chave.



Fonte: Os autores (2024).

Figura 4 – Agrupamentos da rede de coocorrência de palavras-chave por ano de publicação.



Fonte: os autores (2024).

### Sensores Remotos Mais Utilizados

Considerando o total de 30 citações de dados de SR identificadas nos artigos (Quadro 2), foi observado que 24 utilizaram-se de técnicas de imageamento por sensor óptico. 5 abordagens foram do tipo SAR, e apenas uma utilizou a técnica conhecida como LiDAR.

Quadro 2 – Sensores remotos e artigos em que foram utilizados.

| Sensores         | Tipo do Sensor | Artigos                                 |
|------------------|----------------|-----------------------------------------|
| ALOS/PALSAR      | SAR            | [9],[13]                                |
| Hymap            | Hiperespectral | [4]                                     |
| Landsat 5/TM     | Multiespectral | [8]                                     |
| Landsat 7/ETM+   | Multiespectral | [17]                                    |
| Landsat 8/OLI    | Multiespectral | [5],[7],[11],[14],[17]                  |
| LVIS             | LiDAR          | [4]                                     |
| MODIS            | Multiespectral | [1],[2],[8]                             |
| PlanetScope      | Multiespectral | [15]                                    |
| CHRIS/Proba-1    | Hiperespectral | [3],[6]                                 |
| Planet/Rapid Eye | Multiespectral | [21]                                    |
| Sentinel-1       | SAR            | [7],[15],[18]                           |
| Sentinel-2/MSI   | Multiespectral | [10],[13],[15],[16],[18],[19],[20],[21] |
| Spot-5           | Multiespectral | [12]                                    |

Elaboração: Os autores (2024).

Em relação às abordagens de imageamento óptico, 21 citações foram identificadas como abordagens multiespectrais, enquanto 3 foram do tipo hiperespectral. Com dados SAR, 3 abordagens utilizaram dados Sentinel-1 e 2 abordagens utilizaram-se do sensor ALOS/PALSAR. A única aplicação de LiDAR foi identificada no trabalho Li et al. (2017), que se utilizaram de dados LVIS, integrados a uma abordagem hiperespectral, para classificar áreas de transição de estágios de sucessão, em uma área de ocorrência de floresta tropical seca localizada na Costa Rica. Além disso, também foram identificadas

outras publicações que utilizaram de técnicas de integração de dados de SR oriundos de diferentes sensores, conforme dispõe o Quadro 3.

Quadro 3 – Artigos que apresentaram abordagem de integração entre sensores.

| Artigos | Sensores                                     |
|---------|----------------------------------------------|
| [7]     | Landsat 8/OLI; Sentinel-1/SAR                |
| [8]     | MODIS; Landsat 5/TM; Landsat 8/OLI           |
| [13]    | Sentinel-2/MSI; ALOS/PALSAR                  |
| [15]    | Planet Scope; Sentinel-1/SAR; Sentinel-2/MSI |
| [17]    | Landsat 7/ETM+; Landsat 8/OLI                |
| [18]    | Sentinel-1/SAR; Sentinel-2/MSI               |
| [21]    | Sentinel-2/MSI; RapidEye                     |

Elaboração: Os autores (2024).

### Algoritmos de Abordagem ML Mais Utilizados

Conforme dispõe o Quadro 4, o algoritmo RF foi o mais utilizado, tendo sido identificadas 15 citações de um total de 39. Destacaram-se também os algoritmos SVM, ANN e DTs, registrando de 4 a 6 citações, e o algoritmo *k-Nearest Neighbours* (*k*-NN), com 2 citações. Os demais algoritmos identificados tiveram apenas uma citação.

Quadro 4 – Algoritmos de abordagem ML e artigos em que foram utilizados.

| Algoritmos                                                             | Artigos                                                                               |
|------------------------------------------------------------------------|---------------------------------------------------------------------------------------|
| <i>Artificial Neural Networks</i> (ANN)                                | [5], [14], [19], [20]                                                                 |
| <i>Decision Trees</i> (DT)                                             | [3], [5], [6], [8]                                                                    |
| <i>Extreme Gradient Boosting</i> (XGBL)                                | [21]                                                                                  |
| <i>Extreme Tree Classifier</i> (ETC)                                   | [18]                                                                                  |
| <i>Generalized Additive Mixed Model</i> (GAMM)                         | [19]                                                                                  |
| <i>Gradient Boosting</i> (GBM)                                         | [21]                                                                                  |
| <i>k-Nearest Neighbours</i> ( <i>k</i> -NN)                            | [14], [19]                                                                            |
| <i>Long Short-Term Memory</i> (LSTM)                                   | [17]                                                                                  |
| <i>Mahalanobis Distance</i> (MD)                                       | [5]                                                                                   |
| <i>Multi-task Learning Based Machine Learning Classifier</i> (MLC-MTC) | [4]                                                                                   |
| <i>Quantile Regression Neural Networks</i> (QRNN)                      | [21]                                                                                  |
| <i>Random Forest</i> (RF)                                              | [1], [7], [9], [10], [11], [12], [13], [14], [15], [16], [17], [18], [19], [20], [21] |
| <i>Support Vector Machines</i> (SVM)                                   | [2], [5], [6], [14], [19], [21]                                                       |

Elaboração: Os autores (2024).

Identificou-se também que uma quantidade relevante das publicações utilizou mais de um modelo de ML com o intuito de analisar de modo comparativo o desempenho dos algoritmos, conforme dispõe o Quadro 5.

Quadro 5 - Artigos que apresentaram análise comparativa entre algoritmos.

| Artigos | Algoritmos                          |
|---------|-------------------------------------|
| [5]     | Ensemble (DT, MD, ANN, SVM)         |
| [6]     | SVM, DT                             |
| [14]    | <i>k</i> -NN, SVM, RF, ANN          |
| [17]    | RF, LSTM                            |
| [18]    | RF, ETC                             |
| [19]    | GAMM, <i>k</i> -NN, SVM, ANN, RF    |
| [20]    | ANN, RF                             |
| [21]    | Ensemble (RF, GBM, XGBL, SVM, QRNN) |

Elaboração: Os autores (2024).

## DISCUSSÃO

A gestão e conservação baseada em informação e evidência são necessárias para lidar com a natureza complexa e dinâmica de florestas tropicais secas. Neste sentido, as abordagens de ML em dados de SR demonstram grande potencial para preencher a lacuna entre a ciência e a prática para monitorar e gerenciar florestas naturais, fornecendo informações valiosas para subsidiar a sua conservação (Gyamfi-Ampadu & Gebreslasie, 2021).

Com a análise dos resultados desta RSL, foi possível identificar que as florestas tropicais secas estão sendo pesquisadas a partir de uma grande variedade de métodos envolvendo o uso de SR, os quais incluem a utilização de dados provenientes de sensores ativos (SAR e LiDAR) e passivos (multiespectrais e hiperespectrais), além de diversos algoritmos baseados em ML, sendo observadas diferentes frequências de aplicação.

Verificou-se nos artigos científicos revisados que associações entre variáveis como acurácia e distribuição espacial, biodiversidade e topografia, e dossel e mudanças climáticas, identificadas pelo agrupamento de palavras-chave, possuem forte vinculação, sendo, portanto, temas relevantes a serem investigados em pesquisas futuras. Neste sentido, Al Shafian e Du (2024) destacam que a análise de rede de palavras-chave pode capturar conceitos centrais da pesquisa em andamento, delinear os domínios explorados dentro de tópicos específicos e auxiliar os acadêmicos a descobrir possibilidades potenciais para investigações futuras. Assim, novas pesquisas sobre a aplicação de métodos de ML em dados SR em áreas de florestas tropicais secas podem avaliar a inclusão dessas variáveis nos modelos. Desse modo, conforme discutem os autores supracitados, as palavras-chave assinaladas pelos autores dos artigos revisados não apenas fornecem entendimentos sobre o tema central da pesquisa, mas também servem como um importante recurso para identificar tendências emergentes e lacunas no campo. Nesse sentido, identificou-se lacunas relevantes, como a necessidade de mais estudos que explorem a influência combinada de fatores ecológicos e climáticos sobre a biodiversidade em florestas tropicais secas, bem como a carência de abordagens que considerem a escalabilidade dos modelos de ML para diferentes regiões e biomas. Essas limitações destacam a importância de pesquisas futuras que incorporem novas variáveis e aprimorem a capacidade preditiva dos modelos empregados.

Considerando o intervalo temporal definido para a revisão dos artigos, o maior pico de publicações foi identificado entre 2020 e 2022, o que pode estar associado ao recente crescimento do interesse por pesquisas neste campo, além de aumento dos fundos de pesquisa, maior colaboração entre pesquisadores e maior conscientização acerca da importância análise de florestas tropicais secas por métodos de ML e SR.

Observou-se que cerca de 80% dos artigos analisados foram conduzidos em áreas de estudo localizadas na América Latina, com destaque para Brasil e México totalizando 13 áreas de estudo (61%) dentre as 21 observações. Nesta faixa continental, estão contidas cerca de 66% das florestas tropicais secas globais. Na América Latina, México (38%), Bolívia (25%) e Brasil (17%) são os países da região que possuem as maiores áreas de extensão desse ecossistema (Hesketh & Sanchez-Azofeifa, 2014). No

contexto desta revisão, Brasil e México apresentaram a maior concentração de áreas de estudo. No entanto, Calvo-Rodriguez et al. (2016) frisam que não há correlação neste sentido, pois a maioria dos estudos em florestas tropicais secas ocorrem em países onde há grupos de pesquisas consolidados sobre o tema.

No âmbito das abordagens de SR revisadas, observa-se que abordagens do tipo SAR em florestas tropicais secas possuem o potencial de superar desafios referentes ao imageamento durante a estação chuvosa, onde há uma grande tendência à persistência de cobertura por nuvens, já que estes sensores podem obter informações da cobertura terrestre independentemente das condições de iluminação solar ou cobertura por nuvens (Lechner et al., 2020). Dessa maneira, análises em florestas tropicais secas podem ser conduzidas a partir de séries temporais desse tipo de dado sem que as condições climáticas sejam um fator limitante para a aquisição das informações.

De acordo com Pandey et al. (2018), a vantagem da utilização de dados SAR em relação ao ópticos se deve ao fato da sensibilidade às características do terreno, fazendo com que modelos para obtenção de mapas de uso e cobertura da terra tenham mais confiabilidade na separação de classes. No entanto, apenas 16,6% das abordagens de SR identificadas nesta revisão exploraram o potencial desses dados, o que demonstra que ainda há lacunas e oportunidades de pesquisa que podem ser aproveitadas com a utilização de dados de sensores SAR. O mesmo se aplica para abordagens de sensor LiDAR, presente em apenas uma publicação nesta RSL, que em florestas tropicais secas podem ser utilizadas para obter informações acerca da estrutura e elevação arbórea (Agrawal & Khairnar, 2019). Este resultado é similar ao encontrado por Campos e Masanet (2024), que revisaram sistematicamente a utilização de dados de SR para mensuração de atributos ecológicos de florestas tropicais secas durante o período de 2000 a 2022, e verificaram que apenas 8% das abordagens utilizaram dados provenientes de sensores ativos nesse propósito.

Considerando as abordagens de SR óptico, 87% utilizaram sensores multiespectrais, enquanto apenas 12% utilizaram abordagens hiperespectrais. Nesse sentido, Pandey et al. (2018) destacam que dados hiperespectrais possuem capacidade para detectar mudanças sutis na vegetação de maneira que estes se sobressaem na discriminação entre diferentes tipos de vegetação, quando comparados a dados multiespectrais, indicando que oportunidades de pesquisa neste campo podem ser mais exploradas, a exemplo da investigação da separabilidade entre florestas tropicais secas e outras fitofisionomias florestais (Bendini et al., 2022), uma vez que durante o período chuvoso podem apresentar respostas espectrais bastante similares (Hermuche & Sano, 2011).

Abordagens que se utilizaram de dados da coleção Landsat e Sentinel-2/MSI e MODIS tiveram grande destaque nesta RSL, contabilizando 75% das aplicações de SR, o que pode ser explicada pela disponibilização gratuita desses dados na internet (Agrawal; Khairnar, 2019, Campos; Masanet, 2024). Além desses fatores, acrescenta-se que a maior facilidade de interpretação e menores custos e complexidade de processamento que dados ópticos possuem em relação a outros tipos de sensores, de modo que podem influenciar a escolha por esse tipo de dado (Agrawal; Khairnar, 2019). Chaves et al. (2020) ressaltam que a vasta aplicação de dados da série Landsat e, mais recentemente, Sentinel-2/MSI, possuem potencial para superar desafios relacionados à identificação de diferentes classes de cobertura em gradientes ecológicos heterogêneos. A ampla utilização dos dados Landsat 8/OLI pode ser explicada pela resolução espacial de 30 m e temporal de 16 dias de revisita (ou 8 dias, quando combinado com o Landsat 9/OLI), o que faz destes dados um dos mais adequados para obtenção de informações detalhadas da fenologia das plantas (Chaves et al., 2020). Nesse sentido, os dados Sentinel-2 /MSI também se destacam pela resolução de 10m e 5 dias, nas resoluções espaciais e temporais.

Em relação ao aspecto da integração de dados entre diferentes sensores, 33% das publicações observadas apresentaram abordagens utilizando-se de pelo menos mais de um sensor remoto. De acordo com Vizari (2022), a integração de dados satelitais oriundos de diferentes sensores tem se tornado cada vez mais comum em pesquisas baseadas em SR devido à potencial melhora no desempenho de

classificações de cobertura da terra em trabalhos que se utilizam dessa técnica. Dessa maneira, o crescimento futuro de aplicações envolvendo integração de dados de diferentes sensores e a utilização de séries temporais densas de dados podem representar um grande avanço na pesquisa em SR de florestas tropicais secas, tendo em vista que a utilização integrada de diferentes sensores promove um aumento considerável das resoluções espaciais, espectrais e temporais dos conjuntos de dados (Pandey et al., 2018), além de ainda representarem uma área de conhecimento relativamente limitada, no contexto de florestas secas (Campos; Masanet, 2024).

No âmbito da análise dos algoritmos de abordagem ML, identificou-se o algoritmo RF como o mais utilizado, concentrando 38,5% das aplicações desta revisão. Desenvolvido por Breiman (2001), este algoritmo tem tido grande destaque na área do SR devido a boa qualidade de mapeamento que seus modelos apresentam (Belgiu & Dragut, 2016). Além do mais, tem se destacado em outros estudos de revisão, a exemplo de Klompenburg et al. (2020), em que analisaram sistematicamente os algoritmos de ML mais utilizados para previsão de rendimento agrícola, entre 2008 e 2019, e verificaram o RF como o terceiro mais utilizado (precedido por ANN e Regressão Linear), dentre 77 publicações revisadas. De acordo com Maxwell et al. (2018) a ampla utilização do algoritmo RF pode estar relacionada a alguns fatores como a facilidade de configuração do algoritmo em comparação a outros algoritmos comumente utilizados, como as ANNs e SVMs, uma vez que necessita que poucos parâmetros sejam configurados na sua implementação. Além disso, o RF permite avaliar a importância relativa que variáveis independentes desempenham em seus modelos. Nesta perspectiva, cabe destacar a importância da avaliação de variáveis auxiliares às bandas espectrais nos modelos ML, a exemplo de índices espectrais e dados de elevação, pois conforme destacam Zeferino et al., (2020) a incorporação de informações ambientais aos dados espectrais se apresenta como uma alternativa para melhorar reconhecimento de padrões de ocorrência de vegetação quando há limitação para discriminação espectral, principalmente em ambientes biofísicos complexos com diferentes espécies, como em áreas de ecótono.

Outros algoritmos que registraram mais de uma aplicação nesta revisão foram o SVM, DT, ANN e *k*-NN. Neste sentido, Maxwell et al. (2018) frisam que estes têm sido os métodos de ML que atingiram maior maturidade de aplicações na literatura científica e, por conseguinte, têm sido os mais empregados em análises de SR ultimamente, por apresentarem altas acurácias em tarefas diversas de mapeamento.

Além disso, cabe mencionar que uma particularidade relevante do algoritmo ANN, se dá pelo fato do seu funcionamento apresentar similaridade de arquitetura com as *Deep Neural Networks*, as quais compõem o subdomínio DL, o qual tem apresentado resultados de estado da arte em muitos domínios diferentes, como reconhecimento facial e classificação de imagens (Klompenburg et al., 2020), de modo que se apresenta como um campo de pesquisa promissor no SR de florestas tropicais secas por métodos de ML, devendo ser mais explorado futuramente.

Neste estudo, cerca de 38% dos artigos revisados buscaram analisar comparativamente pelo menos dois algoritmos de ML em áreas de florestas tropicais secas, o que é, conforme apontado por Maxwell et al. (2018) uma boa prática em SR. Além disso, um dos mais importantes questionamentos no SR baseado em ML tem sido o de qual seria o melhor algoritmo a ser empregado em tarefas de mapeamento. Apesar de, notoriamente, o algoritmo RF ter sido o algoritmo mais empregado na literatura, não há evidências científicas suficientes para apontá-lo como o melhor algoritmo a ser utilizado (Maxwell et al., 2018).

Conforme destacam Pandey et al. (2018), o melhor algoritmo a ser empregado dependerá das circunstâncias de cada caso, como por exemplo a resolução dos dados e a qualidade das amostras de treinamento. Dessa maneira, é fundamental que pesquisadores e analistas em SR, quando possível, testem diferentes métodos de ML, de modo que possam verificar qual modelo possui melhor rendimento geral e específico de cada classe de interesse (Maxwell et al., 2018), o que no caso das florestas tropicais secas, constitui um aspecto metodológico fundamental, já que estes ecossistemas se localizam, geralmente, em porções reduzidas, e em paisagens com usos e cobertura da terra heterogêneos.

## CONSIDERAÇÕES FINAIS

A revisão sistemática realizada evidencia um crescente interesse na investigação de florestas tropicais secas por métodos de ML aplicados a dados de SR, refletido na significativa quantidade de publicações concentradas entre 2020 e 2022. Este fenômeno pode ser atribuído a uma combinação de fatores, incluindo o aumento de recursos destinados à pesquisa, a colaboração interdisciplinar e a conscientização sobre a importância de preservar esses ecossistemas vulneráveis. A predominância de estudos focados na América Latina, especialmente no Brasil e no México, sublinha a relevância regional dessas florestas, que abrigam uma porção significativa da biodiversidade global e enfrentam pressões antrópicas intensas. A análise das palavras-chave e das metodologias empregadas revela a diversidade de abordagens no uso de SR e algoritmos de ML. A predominância de sensores ópticos, em detrimento de tecnologias como SAR e LiDAR, indica uma oportunidade significativa para futuras investigações, já que essas últimas podem superar limitações impostas por condições climáticas adversas e fornecer dados mais precisos sobre a estrutura das florestas.

A utilização de algoritmos de ML, com destaque para o RF, demonstra uma maturidade crescente nas aplicações em SR. Contudo, a análise comparativa entre diferentes algoritmos ainda se mostra uma prática necessária, dada a variabilidade dos resultados conforme o contexto da pesquisa. Isso ressalta a importância de abordagens metodológicas robustas e adaptáveis que considerem as particularidades dos ecossistemas em estudo. Além disso, a revisão sistemática identificou lacunas na utilização de certos tipos de dados e algoritmos, sugerindo que futuras pesquisas podem se beneficiar da exploração de novas tecnologias e métodos, a exemplo do DL. Além disso, o potencial inexplorado dos dados hiperespectrais, por exemplo, pode levar a avanços significativos na discriminação de classes vegetais em ambientes complexos.

Por fim, embora este estudo de revisão sistemática tenha fornecido percepções valiosas sobre as tendências e as metodologias em pesquisa sobre florestas tropicais secas, sublinha-se que o mesmo pode apresentar algumas limitações em relação à reprodutibilidade. A escolha das bases de dados e os critérios de inclusão podem ter influenciado os resultados. Assim, contribuições futuras podem analisar outras bases de dados e novos artigos que serão publicados a fim de avaliar as técnicas atualmente empregadas.

## REFERÊNCIAS

- Abade, N., Carvalho Júnior, O. A., Guimarães, R., & De Oliveira, S. (2015). Comparative Analysis of MODIS Time-Series Classification Using Support Vector Machines and Methods Based upon Distance and Similarity Measures in the Brazilian Cerrado-Caatinga Boundary. *Remote Sensing*, 7(9), 12160–12191. <https://doi.org/10.3390/rs70912160>
- Agrawal, S., & Khairnar, G. B. (2019). A comparative assessment of remote sensing imaging techniques: Optical, sar and lidar. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-5/W3, 1–6. <https://doi.org/10.5194/isprs-archives-XLII-5-W3-1-2019>
- Al Shafian, S., & Hu, D. (2024). Integrating Machine Learning and Remote Sensing in Disaster Management: A Decadal Review of Post-Disaster Building Damage Assessment. *Buildings*, 14(8), 2344. <https://doi.org/10.3390/buildings14082344>
- Alba, E., Alexandre, M. L. D. S., Marchesan, J., De Souza, L. S. B., Bezerra, A. C., & Silva, E. A. (2022). Comparação entre Algoritmos de Aprendizado de Máquina para a Identificação de Floresta Tropical Sazonalmente Seca. *Anuário do Instituto de Geociências*, 45, 1–10. [https://doi.org/10.11137/1982-3908\\_2022\\_45\\_40758](https://doi.org/10.11137/1982-3908_2022_45_40758)

- Andres-Mauricio, J., Valdez-Lazalde, J. R., George-Chacón, S. P., & Hernández-Stefanoni, J. L. (2021). Mapping structural attributes of tropical dry forests by combining Synthetic Aperture Radar and high-resolution satellite imagery data. *Applied Vegetation Science*, 24(2), e12580. <https://doi.org/10.1111/avsc.12580>
- Azevedo, D., Urias, G., & Oliveira, L. L. D. (2023). A revisão de literatura como método de pesquisa na geografia: Uma scoping review. *Boletim Paulista de Geografia*, 109(1), 65–88. <https://doi.org/10.54446/bpg.v109i1.2955>
- Barboza, E., Salazar, W., Gálvez-Paucar, D., Valqui-Valqui, L., Saravia, D., Gonzales, J., Aldana, W., Vásquez, H. V., & Arbizu, C. I. (2022). Cover and Land Use Changes in the Dry Forest of Tumbes (Peru) Using Sentinel-2 and Google Earth Engine Data. *The 3rd International Electronic Conference on Forests—Exploring New Discoveries and New Directions in Forests*, 2. <https://doi.org/10.3390/IECF2022-13095>
- Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Bendini, H. N., Fonseca, L. M. G., Matosak, B. M., Mariano, R. F., Haidar, R. F., & Valeriano, D. M. (2022). Evaluating the Separability Between Dry Tropical Forests and Savanna Woodlands in the Brazilian Savanna Using Landsat Dense Image Time Series and Artificial Intelligence. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII-B3-2022, 841–847.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Campos, V. E., & Figueroa-Masanet, A. (2024). A systematic review of remote sensing data to assess dry forests attributes. *Bosque (Valdivia)*, 45(1), 17–41. <https://doi.org/10.4067/s0717-92002024000100017>
- Cardoso, P. V., Seabra, V. da S., Xavier, R. A., Rodrigues, E. de M., & Gomes, A. S. (2021). Mapeamento de áreas de caatinga através do random forrest: Estudo de caso na bacia do rio taperoá. *Geoaraguaia*, 11(Especial Geotecnologias), 55–68. <https://periodicoscientificos.ufmt.br/ojs/index.php/geo/article/view/12743/8441>
- Carvalho Júnior, O. A. (2018). Aplicações e perspectivas do sensoriamento remoto para o mapeamento de áreas inundáveis. *Revista de Geografia*, 35(4), 412–431. <https://doi.org/10.51359/2238-6211.2018.238239>
- Chaves, M., Picoli, M., & Sanches, I. (2020). Recent Applications of Landsat 8/OLI and Sentinel-2/MSI for Land Use and Land Cover Mapping: A Systematic Review. *Remote Sensing*, 12(18), 3062. <https://doi.org/10.3390/rs12183062>
- Farrick, K. K., & Branfireun, B. A. (2013). Left high and dry: A call to action for increased hydrological research in tropical dry forests. *Hydrological Processes*, 27(22), 3254–3262. <https://doi.org/10.1002/hyp.9935>
- Ganem, K. A., Xue, Y., Rodrigues, A. D. A., Franca-Rocha, W., Oliveira, M. T. D., Carvalho, N. S. D., Cayo, E. Y. T., Rosa, M. R., Dutra, A. C., & Shimabukuro, Y. E. (2022). Mapping South America's Drylands through Remote Sensing—A Review of the Methodological Trends and Current Challenges. *Remote Sensing*, 14(3), 736. <https://doi.org/10.3390/rs14030736>
- Gao, Y., Solórzano, J. V., Estoque, R. C., & Tsuyuzaki, S. (2023). Tropical Dry Forest Dynamics Explained by Topographic and Anthropogenic Factors: A Case Study in Mexico. *Remote Sensing*, 15(5), 1471. <https://doi.org/10.3390/rs15051471>
- Garcia-Millan, V. E., Sanchez-Azofeifa, G. A., & Malvarez, G. C. (2015). Mapping Tropical Dry Forest

- Succession With CHRIS/PROBA Hyperspectral Images Using Nonparametric Decision Trees. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(6), 3081–3094.
- Garcia-Millan, V., & Sanchez-Azofeifa, A. (2018). Quantifying Changes on Forest Succession in a Dry Tropical Forest Using Angular-Hyperspectral Remote Sensing. *Remote Sensing*, 10(12), 1865. <https://doi.org/10.3390/rs10121865>
- Gyamfi-Ampadu, E., & Gebreslasie, M. (2021). Two Decades Progress on the Application of Remote Sensing for Monitoring Tropical and Sub-Tropical Natural Forests: A Review. *Forests*, 12(6), 739. <https://doi.org/10.3390/f12060739>
- Hermuche, P., & Sano, E. (2011). Identificação da floresta estacional decidual no vão do paranã, estado de goiás, a partir da análise da reflectância acumulada de imagens do sensor etm+/landsat-7. *Revista Brasileira de Cartografia*, 63(3). <https://doi.org/10.14393/rbcv63n3-43750>
- Hernández-Stefanoni, J. L., Castillo-Santiago, M. Á., Mas, J. F., Wheeler, C. E., Andres-Mauricio, J., Tun-Dzul, F., George-Chacón, S. P., Reyes-Palomeque, G., Castellanos-Basto, B., Vaca, R., & Dupuy, J. M. (2020). Improving aboveground biomass maps of tropical dry forests by integrating LiDAR, ALOS PALSAR, climate and field data. *Carbon Balance and Management*, 15(1), 15. <https://doi.org/10.1186/s13021-020-00151-6>
- Herrmann, P. B., Nascimento, V. F., & Freitas, M. W. D. D. (2022). Sensoriamento Remoto Aplicado à Análise de Fogo em Formações Campestres: Uma Re-visão Sistemática. *Revista Brasileira de Cartografia*, 74(2), 437–458. <https://doi.org/10.14393/rbcv74n2-63739>
- Hesketh, M., & Sanchez-Azofeifa, A. (2014). A Review of Remote Sensing of Tropical Dry Forests. Em A. Sanchez-Azofeifa, J. S. Powers, G. W. Fernandes, & M. Quesada (Orgs.), *Tropical Dry Forests in the Americas: Ecology, Conservation and Management* (p. 83–100). CRC Press.
- Huechacona-Ruiz, A. H., Dupuy, J. M., Schwartz, N. B., Powers, J. S., Reyes-García, C., Tun-Dzul, F., & Hernández-Stefanoni, J. L. (2020). Mapping Tree Species Deciduousness of Tropical Dry Forests Combining Reflectance, Spectral Unmixing, and Texture Data from High-Resolution Imagery. *Forests*, 11(11), 1234. <https://doi.org/10.3390/f11111234>
- Klompenburg, T., Kassahun, A., & Catal, C. (2020). Crop yield prediction using machine learning: A systematic literature review. *Computers and Electronics in Agriculture*, 177, 105709. <https://doi.org/10.1016/j.compag.2020.105709>
- Lechner, A. M., Foody, G. M., & Boyd, D. S. (2020). Applications in Remote Sensing to Forest Ecology and Management. *One Earth*, 2(5), 405–412. <https://doi.org/10.1016/j.oneear.2020.05.001>
- Li, W., Cao, S., Campos-Vargas, C., & Sanchez-Azofeifa, A. (2017). Identifying tropical dry forests extent and succession via the use of machine learning techniques. *International Journal of Applied Earth Observation and Geoinformation*, 63, 196–205. <https://doi.org/10.1016/j.jag.2017.08.003>
- Lycarião, D., Roque, R., & Costa, D. (2023). Revisão Sistemática de Literatura e Análise de Conteúdo na Área da Comunicação e Informação: O problema da confiabilidade e como resolvê-lo. *Transinformação*, 35, e220027. <https://doi.org/10.1590/2318-0889202335e220027>
- Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, 39(9), 2784–2817. <https://doi.org/10.1080/01431161.2018.1433343>
- Miles, L., Newton, A. C., DeFries, R. S., Ravilious, C., May, I., Blyth, S., Kapos, V., & Gordon, J. E. (2006). A global overview of the conservation status of tropical dry forests. *Journal of Biogeography*, 33(3), 491–505. <https://doi.org/10.1111/j.1365-2699.2005.01424.x>
- Pandey, P. C., Koutsias, N., Petropoulos, G. P., Srivastava, P. K., & Ben Dor, E. (2021). Land use/land

- cover in view of earth observation: Data sources, input dimensions, and classifiers—a review of the state of the art. *Geocarto International*, 36(9), 957–988. <https://doi.org/10.1080/10106049.2019.1629647>
- Pennington, R. T., Prado, D. E., & Pendry, C. A. (2000). Neotropical seasonally dry forests and Quaternary vegetation changes. *Journal of Biogeography*, 27(2), 261–273. <https://doi.org/10.1046/j.1365-2699.2000.00397.x>
- Portal de Periódicos CAPES. (2024). Acesso CAFe. <https://www.periodicos.capes.gov.br>
- Reyes-Palomeque, G., Dupuy, J. M., Portillo-Quintero, C. A., Andrade, J. L., Tun-Dzul, F. J., & Hernández-Stefanoni, J. L. (2021). Mapping forest age and characterizing vegetation structure and species composition in tropical dry forests. *Ecological Indicators*, 120, 106955. <https://doi.org/10.1016/j.ecolind.2020.106955>
- Rocha, A. M., Leite, M. E., & Espírito-Santo, M. M. D. (2020). Monitoring of Brazilian Deciduous Seasonal Forest by Remote Sensing. *Mercator*, 19(2020), 1–20. <https://doi.org/10.4215/rm2020.e19022>
- Sampaio, R., & Mancini, M. (2007). Estudos de revisão sistemática: Um guia para síntese criteriosa da evidência científica. *Revista Brasileira de Fisioterapia*, 11(1), 83–89. <https://doi.org/10.1590/S1413-35552007000100013>
- Schröder, J. M., Rodríguez, L. P., & Günter, S. (2021). Research trends: Tropical dry forests: The neglected research agenda? *Forest Policy and Economics*, 122, 102333. <https://doi.org/10.1016/j.forpol.2020.102333>
- Sesnie, S., Espinosa, C., Jara-Guerrero, A., & Tapia-Armijos, M. (2023). Ensemble Machine Learning for Mapping Tree Species Alpha-Diversity Using Multi-Source Satellite Data in an Ecuadorian Seasonally Dry Forest. *Remote Sensing*, 15(3), 583. <https://doi.org/10.3390/rs15030583>
- Shafri, H. Z. M. (2017). Machine Learning in Hyperspectral and Multispectral Remote Sensing Data Analysis. *Artificial Intelligence Science and Technology*, 3–9. [https://doi.org/10.1142/9789813206823\\_0001](https://doi.org/10.1142/9789813206823_0001)
- Shimizu, K., Ota, T., & Mizoue, N. (2019). Detecting Forest Changes Using Dense Landsat 8 and Sentinel-1 Time Series Data in Tropical Seasonal Forests. *Remote Sensing*, 11(16), 1899. <https://doi.org/10.3390/rs11161899>
- Singh, C., Karan, S. K., Sardar, P., & Samadder, S. R. (2022). Remote sensing-based biomass estimation of dry deciduous tropical forest using machine learning and ensemble analysis. *Journal of Environmental Management*, 308, 114639. <https://doi.org/10.1016/j.jenvman.2022.114639>
- Smith, W. K., Dannenberg, M. P., Yan, D., Herrmann, S., Barnes, M. L., Barron-Gafford, G. A., Biederman, J. A., Ferrenberg, S., Fox, A. M., Hudson, A., Knowles, J. F., MacBean, N., Moore, D. J. P., Nagler, P. L., Reed, S. C., Rutherford, W. A., Scott, R. L., Wang, X., & Yang, J. (2019). Remote sensing of dryland ecosystem structure and function: Progress, challenges, and opportunities. *Remote Sensing of Environment*, 233, 111401. <https://doi.org/10.1016/j.rse.2019.111401>
- Talukdar, S., Singha, P., Mahato, S., Shahfahad, Pal, S., Liou, Y.-A., & Rahman, A. (2020). Land-Use Land-Cover Classification by Machine Learning Classifiers for Satellite Observations—A Review. *Remote Sensing*, 12(7), 1135. <https://doi.org/10.3390/rs12071135>
- Vargas-Sanabria, D., & Campos-Vargas, C. (2018). Sistema multi-algoritmo para la clasificación de coberturas de la tierra en el bosque seco tropical del Área de Conservación Guanacaste, Costa Rica. *Revista Tecnología en Marcha*, 31(1), 58–69. <https://doi.org/10.18845/tm.v31i1.3497>
- Verhegghen, A., Kuzelova, K., Syrris, V., Eva, H., & Achard, F. (2022). Mapping Canopy Cover in

- African Dry Forests from the Combined Use of Sentinel-1 and Sentinel-2 Data: Application to Tanzania for the Year 2018. *Remote Sensing*, 14(6), 1522. <https://doi.org/10.3390/rs14061522>
- Vizzari, M. (2022). PlanetScope, Sentinel-2, and Sentinel-1 Data Integration for Object-Based Land Cover Classification in Google Earth Engine. *Remote Sensing*, 14(11), 2628. <https://doi.org/10.3390/rs14112628>
- Wohlfart, C., Wegmann, M., & Leimgruber, P. (2014). Mapping Threatened Dry Deciduous Dipterocarp Forest in South-East Asia for Conservation Management. *Tropical Conservation Science*, 7(4), 597–613. <https://doi.org/10.1177/194008291400700402>
- Zeferino, L. B., Souza, L. F. T. D., Amaral, C. H. D., Fernandes Filho, E. I., & Oliveira, T. S. D. (2020). Does environmental data increase the accuracy of land use and land cover classification? *International Journal of Applied Earth Observation and Geoinformation*, 91, 102128. <https://doi.org/10.1016/j.jag.2020.102128>

#### 4. CARACTERIZAÇÃO REGIONAL

A ecorregião Vão do Paranã, localizada na porção central do bioma Cerrado, está inserida na bacia do rio Paranã, sub-bacia do rio Tocantins (Hermuche; Sano, 2011). O rio Paranã e seus tributários dissecam vales profundos, marcados por níveis de base locais de vários tipos. De modo geral, o divisor entre as bacias do rio São Francisco e Tocantins/Araguaia é uma escarpa na forma de degrau, onde o piso superior da escada drena em direção ao rio São Francisco e o piso inferior constitui o Vão do rio Paranã (Souza et al., 2018).


O Vão do Paranã, enquanto ecorregião (Sano et al., 2019), é caracterizado pela ocorrência de um longo corredor ecológico, constituído por florestas estacionais altamente ameaçadas por atividades agropecuárias e baixíssimos índices de conservação (Arruda et al., 2008). Outras fitofisionomias do Cerrado que ocorrem nessa região são o Cerradão, Cerrado Típico, Cerrado Rupestre, Campo Sujo, Campo Limpo e Matas Ciliares (Hermuche, 2010).

O regime de precipitação apresenta média anual de cerca de 1.600 mm, concentrada nos meses de outubro a abril (Hermuche; Sano, 2011) (Figura 2), sendo o clima da região classificado como Clima Tropical com duas estações bem demarcadas (Aw), com variações para Clima Tropical de Altitude (Cwa) (Hermuche; Ferreira; Sano, 2009; Souza et al., 2018) e temperatura anual média variando entre 24 e 25°C (Nunes; Santos, 2022).

O relevo do Vão do Paranã apresenta significativa variação altimétrica (400 a 1000 m), no entanto, a maior parte de sua área é composta por áreas planas, com as maiores declividades estando concentradas na região centro-leste, ao longo da Serra Geral de Goiás (Souza et al., 2018). Além disso, destaca-se a ocorrência de um corredor de relevos cársticos situado na sua porção leste, coincidindo com a maior concentração de fragmentos de cobertura arbórea da região, conforme mostra a Figura 3, a qual também exhibe outras características ambientais acerca da geologia e pedodologia do Vão do Paranã, disponibilizadas pelo Banco de Informações Ambientais do Instituto Brasileiro de Geografia e Estatística (IBGE, 2025). Dessa forma, a litologia é constituída principalmente por terrenos proterozóicos que afloram na porção centro-sul, representada pelo grupo Bambuí, formado por uma sequência de Calcários, Dolomitos e rochas pelítico-psamíticas, onde ocorrem como principais classes de solos os Latossolos, Argissolos, Cambissolos, Gleissolos, Neossolos,

Plintossolos (Hermuche; Ferreira; Sano, 2009), os quais apresentam limitações ambientais, a exemplo do estresse hídrico e baixa aptidão para atividades de monoculturas, contudo, com aptidão para as atividades pastoris em função de extensas áreas de várzeas de pastagens naturais, que são utilizadas historicamente no processo de ocupação e desenvolvimento da região (Faria; Silva, 2020).


**Figura 2** - Climograma com dados de precipitação referentes a janeiro de 1984 a dezembro de 2024 e temperatura de janeiro de 2000 a dezembro de 2024.



Fonte: Adaptado de CHIRPS (Funk et al., 2015) e MODIS LST (Wan et al., 2021).

Quanto à ocupação humana na região, esta é caracterizada por uma grande intensificação a partir da década de 1970, quando fazendeiros das regiões sul e sudeste do Brasil chegaram para expandir as indústrias madeireira e pecuária, principalmente em áreas de FED (Espírito-Santo et al., 2009). A extração intensiva de madeira terminou na década de 1990, contudo a pecuária continua sendo a principal atividade econômica na região do Vão do Paranã (Espírito-Santo et al., 2009; Faria; Silva, 2020).

**Figura 3 – Contexto ambiental regional.**



Fontes: Adaptado de IBGE (2025) e ESA World Cover (Zanaga et al., 2021).


## 5. MÉTODOS

Esta seção descreve os procedimentos metodológicos realizados no processamento e classificação com algoritmos Random Forest (RF) e Gradient Tree Boost (GTB), aplicados a dados SAR e ópticos das missões Sentinel-1 e Sentinel-2, em diferentes recortes sazonais, para determinação do cenário de classificação mais eficiente para a identificação de FEDs na ecorregião do Vão do Paranã.

### 5.1. Área de estudo

A área-piloto selecionada para condução do estudo (Figura 4) compreende cerca de 1000 km<sup>2</sup>, insere-se na ecorregião Vão do Paranã, no nordeste de Goiás, onde há ocorrência significativa de formações florestais como a FED, Cerradão e Matas Ciliares (Faria; Silva, 2020; Hermuche; Sano, 2011).

**Figura 4** - Localização da área de estudo, com *layout* principal (A) apresentando imagem Sentinel-2, com composição RGB 8-4-3.



Fonte: elaboração própria.

### 5.2. Dados de sensoriamento remoto utilizados

Os dados de sensoriamento remoto utilizados para elaboração dos conjuntos de dados para classificação estão descritos no Quadro 1.


**Quadro 1** - Dados de sensoriamento utilizados na pesquisa e respectiva aplicação.

| Sensor/Produto                                                                                                         | Resolução espacial / temporal | Período   | Aplicação                                 | Fonte                                    |
|------------------------------------------------------------------------------------------------------------------------|-------------------------------|-----------|-------------------------------------------|------------------------------------------|
| MODIS LST<br>(MOD11A2.061<br><i>Terra Land Surface Temperature and Emissivity 8-Day Global 1km</i> )                   | 1 km / 8 dias                 | 2000–2024 | Elaboração do climograma                  | Wan et al. (2021)                        |
| CHIRPS (CHIRPS<br><i>Pentad: Climate Hazards Center InfraRed Precipitation With Station Data (Version 2.0 Final)</i> ) | ~5 km / 5 dias                | 1984–2024 | Elaboração do climograma                  | Funk et al. (2015)                       |
| Sentinel-1 SAR<br>(Sentinel-1 SAR<br><i>GRD: C-band Synthetic Aperture Radar Ground Range Detected, log scaling</i> )  | 10 m / 6 dias                 | 2023–2024 | Variáveis preditoras para classificação   | Earth Engine Data Catalog (Google, 2025) |
| Sentinel-2<br>(Harmonized Sentinel-2 MSI: MultiSpectral Instrument, Level-2A (SR))                                     | 10–20 m / 5 dias              | 2023–2024 | Variáveis preditoras para classificação   | Earth Engine Data Catalog (Google, 2025) |
| NASADEM (NASA<br><i>SRTM Digital Elevation 30m</i> )                                                                   | 30 m                          | 2000      | Elevação e declividade para classificação | NASA JPL (2020)                          |

Fonte: Elaboração própria.

### 5.3. Processamento dos dados

A rotina de processamento implementada na plataforma GEE foi desenvolvida conforme mostra o fluxograma da Figura 5.

**Figura 5 - Fluxograma do processamento na plataforma GEE.**

Fonte: elaboração própria.

### 5.3.1. Dados climáticos

Para a caracterização da sazonalidade da área de estudo e definição dos recortes temporais utilizados na classificação, foram empregadas séries de dados de precipitação do CHIRPS (Funk et al., 2015) e temperatura da superfície terrestre do MODIS LST (Wan et al., 2021), acessados e processados na plataforma Google Earth Engine (GEE), para elaboração de um climograma da área de estudo. A partir dessa análise, constatou-se que a estação úmida (maior precipitação) compreende o período entre outubro e abril, enquanto a estação seca (menor precipitação) abrange os meses de julho a setembro. Com base nessa dinâmica sazonal, foram definidos os recortes temporais utilizados na composição das imagens SAR e ópticas empregadas nas análises posteriores.

### 5.3.2. Processamento dos dados SAR

As séries de dados SAR, do Sentinel-1, foram processadas considerando o ano hidrológico entre 01-10-2023 e 30-09-2024, utilizando todas as imagens disponíveis para o período, totalizando 119 imagens. Além da utilização das polarizações VV e VH, foram derivados o índice RVI (*Radar Vegetation Index*), conforme sugerido por Prodromou et al. (2024), e a razão simples VV/VH, com base em Soudani et al. (2021) e Prudente et al. (2022), com o objetivo de incorporar informações estruturais adicionais. Posteriormente, foram calculados os percentis 25 e 75 para todas as variáveis SAR, conforme sugerido em Xie; Liu e Yang (2020) e Zeng et al. (2020), visando ampliar o conjunto de atributos utilizados pelos algoritmos de classificação. Para definição dos recortes sazonais, foram considerados os meses de outubro a março para a estação úmida (42 imagens SAR) e julho a setembro para a estação seca (30 imagens). Como medida estatística resumo para agregação temporal das séries de imagens, foi empregada a composição mediana, visando reduzir o ruído *speckle* e capturar características representativas das diferentes classes de uso e cobertura da terra em imagens SAR (Costa; Freitas, 2024).

### 5.3.3. Processamento dos dados ópticos

Os dados ópticos foram elaborados a partir de 78 imagens do Sentinel-2 com até 22% de cobertura por nuvens, considerando o mesmo período hidrológico e os mesmos recortes sazonais definidos para os dados SAR, contudo para a estação úmida foram obtidas 22 imagens, enquanto para a estação seca 31. Além das bandas espectrais, foram calculados os índices NDVI (*Normalized Difference Vegetation Index*), SAVI (*Soil Adjusted Vegetation Index*) e NDWI (*Normalized Difference Water Index*), com o intuito de fornecer informações adicionais para a separabilidade entre classes (Li et al., 2022; Zeferino et al., 2020). Em seguida, também foram calculados os percentis 25 e 75 para todas as bandas e índices derivados, agregando variabilidade temporal e informações complementares aos modelos de classificação. Para a agregação temporal dos dados ópticos também foi utilizada a mediana, amplamente empregada para reduzir a influência de valores extremos, como nuvens e sombras, e gerar composições representativas das condições da superfície em imagens ópticas (Nolasco; Balzarini, 2025).

#### 5.3.4. Processamento dos dados de elevação

Como variáveis auxiliares aos modelos de classificação, foram incorporados os atributos topográficos elevação e declividade, os quais foram derivados do modelo digital de elevação NASADEM (NASA JPL, 2020). A inclusão dessas variáveis baseou-se em evidências de que diferentes classes de cobertura vegetal apresentam distribuição associada a gradientes topográficos, contribuindo para aumentar a discriminação entre classes (Li et al., 2022; Tsai et al., 2018). Esses atributos foram integrados aos conjuntos de dados SAR e ópticos como variáveis explicativas adicionais nos modelos de classificação, os quais foram posteriormente combinados com as composições temporais geradas a partir do filtro mediana.

#### 5.3.5. Elaboração dos conjuntos de dados para classificação

Foram elaborados nove conjuntos de dados para classificação (Tabela 1), estruturados a partir de diferentes composições de dados SAR, ópticos, variáveis topográficas e distintos períodos sazonais. Conforme proposto por Chen et al. (2023), os conjuntos de dados foram reamostrados para 10 m, utilizando a configuração *default* (*nearest-neighbor*). Esses conjuntos foram utilizados como entrada para os algoritmos Random Forest (RF) e Gradient Tree Boost (GTB), totalizando 18 modelos de classificação, cuja comparação permitiu identificar as combinações de dados e abordagens com melhor desempenho para o mapeamento de FEDs.

**Tabela 1** - Conjuntos de dados elaborados para classificação.

| <b>Conjuntos de dados elaborados</b> | <b>Composição dos conjuntos de dados</b>                                                                                           | <b>Variável temporal</b> | <b>Quantidade de imagens utilizadas</b> | <b>Quantidade de variáveis</b> |
|--------------------------------------|------------------------------------------------------------------------------------------------------------------------------------|--------------------------|-----------------------------------------|--------------------------------|
| Conjunto de dados 1                  | Mediana (VV + VH + RVI + razão VV/VH) + percentis (25 e 75) + elevação e declividade                                               | Úmida                    | 42                                      | 14                             |
| Conjunto de dados 2                  | Mediana (VV + VH + RVI + razão VV/VH) + percentis (25 e 75) + elevação e declividade                                               | Seca                     | 30                                      | 14                             |
| Conjunto de dados 3                  | Mediana (VV + VH + RVI + razão VV/VH) + percentis (25 e 75) + elevação e declividade                                               | Anual                    | 119                                     | 14                             |
| Conjunto de dados 4                  | Mediana (bandas 2 a 8A, 11 e 12 + NDVI + NDWI + SAVI) + percentis (25, 75) + elevação e declividade                                | Úmida                    | 22                                      | 41                             |
| Conjunto de dados 5                  | Mediana (bandas 2 a 8A, 11 e 12 + NDVI + NDWI + SAVI) + percentis (25, 75) + elevação e declividade                                | Seca                     | 31                                      | 41                             |
| Conjunto de dados 6                  | Mediana (bandas 2 a 8A, 11 e 12 + NDVI + NDWI + SAVI) + percentis (25, 75) + elevação e declividade                                | Anual                    | 78                                      | 41                             |
| Conjunto de dados 7                  | Mediana (bandas 2 a 8A, 11 e 12 + NDVI + NDWI + SAVI + VV + VH + RVI + razão VV/VH) + percentis (25 e 75) + elevação e declividade | Úmida                    | 64                                      | 53                             |
| Conjunto de dados 8                  | Mediana (bandas 2 a 8A, 11 e 12 + NDVI + NDWI + SAVI + VV + VH + RVI + razão VV/VH) + percentis (25 e 75) + elevação e declividade | Seca                     | 61                                      | 53                             |
| Conjunto de dados 9                  | Mediana (bandas 2 a 8A, 11 e 12 + NDVI + NDWI + SAVI + VV + VH + RVI + razão VV/VH) + percentis (25 e 75) + elevação e declividade | Anual                    | 197                                     | 53                             |


Fonte: elaboração própria.

#### 5.4. Amostragem

O procedimento de amostragem foi conduzido por meio de interpretação visual de imagens ópticas da área de estudo, adquiridas durante a estação seca, período no qual a distinção de alvos com comportamento decíduo se torna mais evidente (Hermuche; Sano, 2011; Portillo-Quintero; Sanchez-Azofeifa, 2010). Dessa forma, além da FED, foram definidas para a amostragem as classes AFL (Afloramento Rochoso), AGR (Agropecuária), CA/CH (Campo Alagado ou Corpos Hídricos), CMP (Formação Campestre) e CRD (Cerradão), MC/G (Mata Ciliar ou de Galeria).

Ao todo foram coletados 910 pontos amostrais (Figura 6), distribuídos de forma equitativa entre as classes, totalizando 130 amostras por classe. Desses, 70% foram destinados ao treinamento dos classificadores e 30% à etapa de teste, para avaliação do desempenho dos modelos. Além disso, para obtenção de maior confiabilidade durante o procedimento de amostragem de classes presentes na área de estudo foram utilizados produtos de cobertura e uso da terra sobrepostos à área amostrada, tais como o MODIS Land Cover (Friedl; Sulla-Menasse, 2022), ESA WorldCover 2020 (Zanaga et al., 2021) e MAPBIOMAS (2025) (Quadro 2).

**Figura 6** - Pontos amostrais coletados e variação altimétrica da área de estudo.



Fonte: elaboração própria.

**Quadro 2** - Classes utilizadas na amostragem, descrição e produto de cobertura da terra utilizado como referência para coleta de pontos amostrais.

| Classes | Descrição                                                                  | Produto de referência                                              |
|---------|----------------------------------------------------------------------------|--------------------------------------------------------------------|
| FED     | Florestas decíduas não associadas a cursos d'água.                         | Modis Land Cover (Friedl; Sulla-Menashe, 2022).                    |
| CRD     | Florestas perenes não associadas a cursos d'água.                          | ESA World Cover (Zanaga et al., 2021); MODIS Land Cover (2022).    |
| AGR     | Mosaicos de pastagens e pequenas culturas agrícolas.                       | MapBiomass (2025); MODIS Land Cover (Friedl; Sulla-Menashe, 2022). |
| CMP     | Campos naturais de Cerrado, dominados por gramíneas e vegetação arbustiva. | MapBiomass (2025).                                                 |
| CA/CH   | Áreas permanentemente úmidas e pequenos corpos hídricos                    | MapBiomass (2025).                                                 |
| AFL     | Afloramento de substrato rochoso com menos de 10% de vegetação.            | MapBiomass (2025).                                                 |
| MC/G    | Florestas perenes que acompanham o leito dos rios.                         | ESA World Cover (Zanaga et al., 2021).                             |

Fonte: elaboração própria.

## 5.5. Classificação e avaliação


Os classificadores RF e GTB, configurados com o valor 500 para o parâmetro *ntree*, e *default* para os demais parâmetros customizáveis (raiz quadrada da quantidade de variáveis de entrada dos modelos para o parâmetro *mtry*, no caso do RF, além de 0,1 e 3, respectivamente para os parâmetros *learning rate* e *maximum depth*, para o algoritmo GTB), conforme sugerido em estudos prévios (Maxwell et al., 2018; Savitha; Talari, 2025; Srivastava et al., 2022). Após a realização das classificações foi utilizado o filtro de refinamento *Connected Pixels* para redução de pixels isolados (efeito sal e pimenta), para posterior elaboração dos *layouts* finais.

Para a avaliação dos modelos de classificação, foram utilizadas as métricas derivadas da Matriz de Confusão, Acurácia Geral (AG), obtida pela divisão do total de pixels classificados corretamente pelo total de pixels na Matriz de Confusão, Acurácia do Produtor (AP), obtida pela divisão do total de pixels classificados corretamente em uma categoria pelo total de pixels nessa categoria (dados de referência), Acurácia do Consumidor (AC), obtida pela divisão do total de pixels classificados corretamente em uma categoria pelo número total de pixels classificados nessa categoria; (Gyamfi-Ampadu; Gebreslasie; Mendoza-Ponce, 2020). Adicionalmente, foram calculados os erros omissão (valor complementar da métrica AP), bem como erros de comissão

(valor complementar da métrica AC) (Congalton; Green, 2019) para todas as classes avaliadas nos modelos.

Além disso, também foram utilizadas as métricas F1-score (F1), a qual consiste na média harmônica entre as AP e AC (Nasiri et al. 2022), e a Importância de Variável, obtida pela função “Explain” no GEE (Chen et al., 2023), como forma de mensurar a qualidade das classificações. Para interpretação dos valores gerados pelas métricas de avaliação, foram utilizados os intervalos exibidos na Figura 6.

**Figura 6 - Interpretação dos níveis de acurácia.**




Fonte: Adaptado de Aurup (2011).

## 6. RESULTADOS

### 6.1. Resultados gerais das classificações


Os resultados da avaliação pela métrica AG são apresentados no mapa matricial da Figura 7, o qual evidencia o desempenho comparativo dos modelos testados e permite identificar padrões de variação associados aos diferentes conjuntos de dados e algoritmos empregados. Complementarmente, a Figura 8 apresenta o ranqueamento dos 10 modelos com melhor desempenho, destacando as combinações que alcançaram os maiores valores de AG. Dessa forma, foi verificado que os modelos de classificação GTB obtiveram resultados superiores aos modelos RF, apresentando maior AG na ampla maioria dos modelos de classificação, conforme ilustra a Figura 9. Os modelos SAR obtiveram acurácias moderadas (72,22-79,46% de AG) para as estações seca e anual, enquanto a maioria dos modelos ópticos e integrados atingiram acurácias classificadas como muito altas ( $AG > 90\%$ ). O resultado com maior AG foi obtido pelo modelo GTB SAR + óptico / seca, com AG de 94,62%, enquanto o menor foi obtido pelo modelo RF SAR / úmida, com 65,60%.

**Figura 7** - Mapa matricial da avaliação geral dos modelos de classificação.




Fonte: elaboração própria.

**Figura 8** - Ranqueamento dos modelos de classificação que alcançaram as 10 maiores AGs.



Fonte: elaboração própria.

**Figura 9** - Comparação de resultados gerais entre o RF e GTB para as combinações temporais.



Fonte: elaboração própria.

No âmbito dos modelos de classificação SAR, o melhor resultado geral foi obtido com o modelo GTB SAR / anual, com 79,46% de AG. Além do menor resultado

geral pela métrica AG (RF SAR / úmida), o segundo menor resultado foi obtido pelo modelo GTB SAR / úmida (68,43%).

Entre os modelos de classificação exclusivamente ópticos, o maior valor de AG foi obtido pelo modelo GTB anual (94,40%), correspondendo ao segundo melhor desempenho entre todos os modelos avaliados, enquanto o menor valor foi registrado para o modelo RF óptico/úmida (85,51%).

Nos modelos integrados, o melhor desempenho geral foi alcançado pelo modelo GTB SAR + óptico/anual, com AG de 94,62%, seguido pelo modelo RF SAR + óptico/seca, com 94,05%. O menor desempenho desse grupo foi observado para o modelo RF SAR + óptico/úmida, com AG de 90,40%.

Em relação à variável temporal, as composições anuais e da estação seca concentraram os melhores resultados, sendo responsáveis por oito dos dez modelos com maiores valores de AG.

Nos modelos baseados exclusivamente em dados SAR, o maior desempenho foi observado para o modelo GTB SAR/anual, com AG de 79,46%, enquanto o menor valor ocorreu no modelo RF SAR/úmida, com 65,60%.

De modo consistente, as composições anuais também apresentaram os melhores resultados nos modelos ópticos e integrados. Para os modelos ópticos, o maior valor de AG foi obtido pelo GTB óptico/anual (94,40%), enquanto o menor ocorreu no RF óptico/úmida (85,51%). Entre os modelos integrados, a maior AG foi registrada para o GTB SAR + óptico/anual (94,62%), ao passo que o menor desempenho foi observado no RF SAR + óptico/úmida (90,40%).

De forma geral, os resultados indicam superioridade das composições anuais e da estação seca, bem como maior desempenho dos modelos integrados em relação aos modelos exclusivamente SAR. Adicionalmente, os resultados evidenciam que, para as combinações de dados analisadas, os melhores desempenhos de mapeamento estiveram associados aos modelos construídos com a série anual de dados e classificados com o algoritmo GTB.

## 6.2. Resultados das classificações agrupadas por classe

Na Figura 10 é apresentada a distribuição espacial das classes mapeadas pelos modelos de classificação SAR, enquanto na Figura 11 estão dispostos resultados da avaliação a nível classe de tais modelos.

**Figura 10** - Layouts das classificações dos conjuntos de dados SAR.

(A) RF SAR / úmida



(B) GTB SAR / úmida



(C) RF SAR / seca




(D) GTB SAR / seca



(E) RF SAR / anual




(F) GTB SAR / anual



Fonte: elaboração própria.

Visualmente, os erros de classificação foram mais perceptíveis pela inclusão exacerbada da classe MC/G sobre áreas de FED e AGR, bem como a classe CRD sendo incluída erroneamente sobre áreas de FED.

**Figura 11 - Avaliação das classes mapeadas nos modelos SAR.**



Fonte: elaboração própria.

Considerando os modelos de classificação SAR, a classe CRD obteve melhores acurácias em relação às demais classes de vegetação florestal, sendo a única dessas a alcançar resultados aceitáveis (acima de 70%) em pelo menos duas combinações temporais (seca e anual), com destaque para o modelo GTB SAR / seca e GTB SAR / anual, em que essa classe alcançou os maiores valores de F1, com respectivamente 77,55% e 78,65%. Já as menores acurácias para as fitofisionomias florestais foram observadas no modelo RF SAR / úmida.

Os principais erros de classificação para as classes de vegetação florestal, tomando como referência o modelo SAR que obteve menor AG (RF SAR / úmida), foram observados nos comissionamentos das classes FED sobre AFL e CRD sobre

classe MC/G. Além disso, também foram observados importantes erros de omissão da classe MC/G sobre as classes CRD, AFL e FED.

As melhores métricas de avaliação a nível classe nos modelos SAR se deram nas classes CMP e AGR, exibindo altos valores de F1 (acima de 80%) na ampla maioria dos modelos, com destaque para o modelo GTB para estação seca em que a classe AGR atingiu valor de F1 de 96,77%.

Desse modo, a diferenciação entre classes de vegetação florestal ainda não pode ser atingida com excelência em composições de imagens SAR baseadas principalmente em dados SAR. Contudo, tais dados apresentaram boa confiabilidade para a separabilidade de classes que não incluem vegetação florestal, considerando, principalmente, conjuntos de dados que contenham informações sazonais para estação seca ou série anual.

Posteriormente, a Figura 12 apresenta a distribuição espacial das classes mapeadas pelos modelos de classificação ópticos, enquanto na Figura 13 estão dispostos resultados da avaliação a nível classe dos respectivos modelos.

A maioria dos modelos de classificação baseados nos conjuntos de dados ópticos atingiram resultados gerais de acurácia muito alta ( $AG > 90\%$ ) (com exceção dos modelos para estação úmida), o que indica que as métricas de avaliação a nível classe AP, AC e F1 também atingiram bons resultados de mapeamento.


No contexto das classes de vegetação florestal, as classes FED e MC/G obtiveram seus melhores resultados no modelo GTB ópticos / anual, em que alcançaram os respectivos valores F1 97,43% e 97,20, enquanto o CRD obteve seu melhor valor de F1 no modelo RF ópticos / seca, alcançando o valor 96,55%.

Tomando como referência o modelo de baseado em dados ópticos que obteve menor AG (RF ópticos / úmida), os principais erros de classificação foram observados no comissionamento da FED em MC/G, bem como o comissionamento da classe CRD sobre CA/CH.


Dentre as demais classes, a classe AFL obteve maior destaque ao alcançar 100% de F1 nos modelos classificados pelo RF para as variáveis temporais seca e anual. Além disso, a classe AGR obteve 100% de F1 no modelo classificado pelo GTB, na série anual de dados.

**Figura 12** - Layouts das classificações dos conjuntos de dados ópticos.


(A) RF ópticos / úmida




(B) GTB ópticos / úmida




(C) RF ópticos / seca




(D) GTB ópticos / seca



(E) RF ópticos / anual




(F) GTB ópticos / anual



Fonte: elaboração própria.

**Figura 13 - Avaliação das classes mapeadas nos modelos ópticos.**




Fonte: elaboração própria.

Portanto, no âmbito dos modelos ópticos, as classes FED e MC/G foram melhor identificadas a partir da utilização do algoritmo GTB para as séries de dados anuais, enquanto a classe CRD obteve melhores resultados com a utilização do RF para estação seca. As principais fontes de erros, foram observadas principalmente nos modelos classificados pelo RF para estação úmida, em que áreas de FED foram classificadas erroneamente como MC/G, bem como a classe CRD sendo classificadas erroneamente como CA/CH.


Posteriormente, na Figura 14 é observado a distribuição espacial das classes mapeadas pelos modelos de classificação SAR e ópticos integrados, enquanto na Figura 15 estão dispostos resultados da avaliação a nível classe dos respectivos modelos.

**Figura 14** - Layouts das classificações dos modelos SAR e ópticos integrados.


(A) RF SAR + ópticos / úmida




(B) GTB SAR + ópticos / úmida




(C) RF SAR + ópticos / seca




(D) GTB SAR + ópticos / seca



(E) RF SAR + ópticos / anual



(F) GTB SAR + ópticos / anual




|                                                                                                                                    |                                                                                                                                |                                                                                                                                    |                                                                                                                              |
|------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------|
| <span style="display: inline-block; width: 15px; height: 15px; background-color: brown; border: 1px solid black;"></span> FED      | <span style="display: inline-block; width: 15px; height: 15px; background-color: pink; border: 1px solid black;"></span> AGR   | <span style="display: inline-block; width: 15px; height: 15px; background-color: darkgreen; border: 1px solid black;"></span> MC/G | <span style="display: inline-block; width: 15px; height: 15px; background-color: grey; border: 1px solid black;"></span> AFL |
| <span style="display: inline-block; width: 15px; height: 15px; background-color: lightgreen; border: 1px solid black;"></span> CRD | <span style="display: inline-block; width: 15px; height: 15px; background-color: yellow; border: 1px solid black;"></span> CMP | <span style="display: inline-block; width: 15px; height: 15px; background-color: blue; border: 1px solid black;"></span> CA/CH     |                                                                                                                              |

6 12 km



Fonte: elaboração própria.

**Figura 15 - Avaliação das classes mapeadas nos modelos SAR e ópticos integrados.**



Fonte: elaboração própria.

A avaliação em nível de classe dos modelos integrados revelou acurácias elevadas para as classes analisadas, indicando boa confiabilidade dos resultados e comportamento semelhante ao observado nos modelos ópticos.

As classes de vegetação florestal apresentam melhores resultados de F1 nos modelos para as estações seca e anual. Destaca-se a classe CRD, que obteve o melhor resultado de classificação no modelo GTB para estação anual, em que alcançou 92,30% de F1, enquanto a classe FED conseguiu o melhor resultado no modelo GTB para a série anual de dados, alcançando 98,66% de F1. Já a classe MC/G alcançou o melhor resultado com o modelo RF para série anual, alcançando o valor 98,05%, pela métrica F1.

A maiores erros de classificação foram observados no modelo RF SAR + ópticos / úmida, o qual obteve a menor AG (90,40%). Nesse modelo, os principais erros se deram no comissionamento de áreas de FED sobre as classes MC/G e CRD.


Dentre as demais classes avaliadas, destaca-se a classe AFL, que obteve 100% de F1 nos modelos RF para as estações úmida e seca, e também 100% nos modelos GTB para estação úmida e anual. Além disso, destacou-se também a classe AGR com 100% de F1, no modelo GTB anual.

Com base nos resultados da avaliação em nível de classe dos modelos integrados, verificou-se que as classes FED e CRD alcançaram maior desempenho no modelo GTB anual, ao passo que a classe MC/G apresentou melhor resultado no modelo anual classificado por RF.

### 6.3. Variáveis mais importantes nos modelos de classificação


O ranqueamento das cinco variáveis mais importantes dos modelos de classificação RF e GTB podem ser visualizados, respectivamente, nas Figuras 16 e 17.

**Figura 16** - Ranqueamento das cinco variáveis mais importantes nos modelos de classificação RF.



Fonte: elaboração própria.

**Figura 17 - Ranqueamento das cinco variáveis mais importantes nos modelos de classificação GTB.**



Fonte: elaboração própria.

Dentre todos os modelos de classificação, a variável elevação destacou-se como o atributo que obteve a maior contribuição relativa em todos os modelos, com ênfase nos modelos classificados com o algoritmo GTB, em que apresentou entre 4 e 10% maiores contribuições relativas que os modelos classificados pelo RF. Além disso, destaca-se o modelo GTB SAR / seca, em que a variável elevação registrou a maior contribuição relativa, com 20,84%.

No âmbito dos modelos SAR, além da elevação, destacaram-se também as variáveis declividade e VV\_p25, ocorrendo em cinco modelos, tendo alcançado as maiores contribuições no modelo GTB SAR / úmida, com respectivamente 9,18 e 7,29%.

Considerando os modelos ópticos, as variáveis que mais se destacaram, além da elevação, foram as bandas B11\_p75, a qual esteve ranqueada entre as cinco variáveis mais importantes em quatro modelos de classificação, sendo a maior observada no modelo GTB ópticos / anual, exibindo 5,34%) de contribuição relativa,

bem como a variável *ndwi\_p25*, ranqueada em três modelos ópticos, sendo a maior contribuição observada no modelo GTB ópticos / úmida, com 3,50% de contribuição.

No contexto dos modelos integrados, além da elevação, as variáveis com maior frequência nos ranqueamentos foram os atributos *VV*, *B5\_p75* e *B11\_p75*, ocorrendo em quatro modelos. As maiores contribuições observadas entre essas variáveis foram observadas em modelos classificados pelo algoritmo GTB. As variáveis *VV* e *B5\_p75*, obtiveram os maiores valores de contribuição relativa nos modelos para a série anual, com respectivamente 5,64% e 4,89% de contribuição, enquanto a variável *B11\_p75* obteve a maior contribuição nos modelos para estação seca (5%).

Desse modo, evidenciou-se que às variáveis adicionais incorporadas aos modelos de classificação baseadas na topografia como elevação e declividade, índices espectrais e percentis tiveram grande influência nos resultados obtidos pelas classificações com os algoritmos RF e GTB.

## 7. DISCUSSÃO

Conforme discutido em estudos prévios (Haddad et al., 2023; Hermuche; Felfili, 2011; Hermuche; Sano, 2011), a separabilidade entre classes de cobertura florestal do Cerrado consiste em um importante desafio em pesquisas baseadas em sensoriamento remoto (SR) devido à similaridade na resposta espectral que estas apresentam fora do período de seca. Dessa forma, esta pesquisa teve como objetivo avaliar modelos de classificação RF e GTB para dados SAR e ópticos, com o intuito de identificar a ocorrência de FED na ecorregião Vão do Paranã, a partir de abordagem de processamento de dados em nuvem com a plataforma Google Earth Engine. Os resultados revelaram que é possível obter classificações de alta acurácia, com 10m de resolução espacial, em diferentes abordagens de classificação e combinações temporais de dados.

### 7.1. Integração de dados SAR e ópticos

Yu et al. (2020) ressaltam que por meio de uma análise abrangente de cenários de dados que abrangem combinações de características espectrais, espaciais, topográficas e temporais de diferentes maneiras, é possível entender melhor como projetar uma classificação adequada para produzir um resultado de classificação ideal. Nesta pesquisa, os melhores resultados de AG foram obtidos a partir dos modelos de classificação baseados em dados SAR e ópticos integrados e apenas ópticos, representativos para séries anuais e secas, referentes ao ano hidrológico (outubro 2023 - setembro 2024), enquanto as menores acurácias foram observadas nos modelos baseados de dados SAR. Dessa forma, o modelo GTB SAR + ópticos / anual, tendo a elevação como principal variável preditora, indicou o melhor resultado para separabilidade entre as classes FED e CRD.

Análises baseadas em dados apenas ópticos tendem a apresentar limitações devido à semelhança na reflectância espectral entre diferentes alvos da paisagem, como culturas agrícolas distintas ou espécies arbóreas com fenologia semelhante, que podem se tornar indistinguíveis (Hermuche; Felfili, 2011). Por outro lado, as imagens SAR são afetadas pelo ruído speckle, inerente a esse tipo de sensor, o que pode aumentar a incerteza das medições e reduzir a precisão das classificações (Costa; Freitas, 2024). Nesse contexto, a integração entre dados ópticos e SAR

mostra-se viável, pois a complementaridade entre eles permite que as limitações de um conjunto de dados sejam compensadas pelas potencialidades do outro (Joshi et al., 2016), tal como a abordagem desenvolvida nesta pesquisa demonstrou.

Os resultados gerais da presente pesquisa são coerentes com os que foram encontrados por Symeonakis et al. (2018), no qual analisaram diferentes combinações temporais de dados SAR e ópticos para classificação de vegetação savânica no sul do continente africano utilizando o algoritmo RF, de tal modo que verificaram que o melhor resultado geral resultou combinação séries anuais de dados Landsat 5 e 7 (óptico) e Palsar (SAR), alcançando 90,25% de AG, enquanto as menores acurácias foram observadas nos modelos obtidos pela classificação de dados SAR isolados para estação úmida. Similarmente, Silva et al. (2021) classificaram séries anuais de dados da coleção Sentinel, de forma que obtiveram resultados similares em estudo sobre a vegetação do bioma Cerrado na porção norte de Goiás. Em tal estudo, o resultado geral da classificação do conjunto de dados ópticos (Sentinel-2) foi superior aos dados SAR (Sentinel-1) isolados, enquanto o resultado para o conjunto integrado foi superior às duas abordagens anteriores.

Além do mais, os resultados gerais desta pesquisa também destacam a importância da variável temporal para identificação de classes de vegetação em ambientes heterogêneos, com pronunciada sazonalidade climática, como ocorre no bioma Cerrado (Alencar et al. 2020), uma vez que se observou que dentre os dez modelos de maiores acurácias obtidas, oito foram a partir de combinações temporais de dados para as estações seca e anual.

## 7.2. Desempenho dos algoritmos de classificação e variáveis preditoras

No melhor modelo de classificação obtido na presente pesquisa (GTB SAR + ópticos / anual), as classes FED e CRD obtiveram F1 de 98,60% e 92,30%, respectivamente. Tais resultados são superiores aos obtidos por Bendini et al., (2022), que alcançou, como melhor resultado F1 de 69,90% para FED e 86,99% para CRD, em uma abordagem de *Deep Learning* (DL), com o modelo LSTM, para séries de dados Landsat 7 e 8, o que demonstra a robustez do método desenvolvido na presente pesquisa. Contudo, recomenda-se que mais testes de classificação sejam conduzidos em futuras pesquisas, uma vez que ainda não há um consenso claro na literatura sobre o melhor algoritmo de aprendizado de máquina, pois o algoritmo ideal

provavelmente é específico para cada caso, dependendo das classes mapeadas, da natureza dos dados de treinamento e das variáveis preditoras (Maxwell et al., 2018).

As informações estruturais isoladas fornecidas pela banda C do Sentinel-1 não foram suficientes para alcançar altas acurácias ( $AG > 80\%$ ), tal como observados nos modelos ópticos e integrados, no entanto foram eficientes na diferenciação entre classes que apresentam diferentes características estruturais, a exemplo da diferenciação entre AGR e classes de cobertura florestal FED, CRD e MC/G, similarmente ao observado por Li et al., (2022) a adotar um sistema de classificação binário floresta e não floresta, no sudeste da China. Pavanelli et al. (2018), em estudo sobre a integração de dados SAR Palsar-2 e ópticos Landsat 8, observaram o ganho de informações estruturais para identificar classes de baixa biomassa como as formações campestres, nas quais os dados apenas ópticos não apresentaram bom desempenho. Além disso, as classificações conduzidas de modelos SAR revelaram a importância das variáveis temporais seca e anual, as quais alcançaram acurácias moderadas ( $AG > 70\%$ ), enquanto os modelos para estação úmida obtiveram baixas acurácias, o que pode estar relacionado a maior diferença estrutural captada durante a estação seca pelos sensores SAR (Pavanelli et al., 2018).

No âmbito da análise comparativa de desempenho, o classificador GTB apresentou acurácias superiores na ampla maioria dos modelos de classificação utilizados na presente pesquisa, com sete modelos superiores ao GTB, no comparativo entre combinações temporais, conforme demonstrado na Figura 9. O bom desempenho do GTB pode ser atribuído à sua capacidade de construir modelos complexos e resolver relações complexas entre várias classes, particularmente quando se utilizam grandes conjuntos de dados (Savitha; Talari, 2025). Resultados similares foram encontrados por Chen et al. (2023) e Vorovencii (2024), ao avaliaram o desempenho dos classificadores GTB, RF e CART, de tal forma que observaram que o desempenho do algoritmo GTB foi superior em relação aos demais, alcançando a maior AG, dentre vários conjuntos de dados classificados, para o modelo classificação de imagens multi-sazonais Sentinel-1 e Sentinel-2 integrados. Contudo, recomenda-se que novos métodos de classificação continuem a ser explorados de modo a permitir a obtenção de novos *insights* e conhecimentos acerca do monitoramento da vegetação em ambientes pronunciadamente sazonais como os biomas savânicos.

Conforme apontam Bendini et al. (2022), a combinação de séries temporais de imagens de SR com atributos como elevação e índices espectrais têm a capacidade de adicionar informações valiosas aos algoritmos em tarefas de classificação. Na presente pesquisa, a principal variável explicativa seu deu com o atributo elevação, a qual consistiu no atributo de maior importância relativa em todos os modelos testados. Tal resultado se mostrou pertinente com a distribuição espacial das classes mapeadas pela área de estudo, as quais apresentaram dependência relacionada à elevação, a exemplo das áreas de FED e AGR ocorrendo nas áreas mais baixas (porção a oeste da área de estudo), enquanto classes as CRD, CA/CH e CMP ocorreram na parte mais alta (porção leste da área de estudo). Nesta perspectiva, Waśniewski et al. (2020) verificaram resultados similares em estudo conduzido no Gabão, onde florestas semi-decíduas ocorrem associadas a altas altitudes naquele país, dessa forma, indicando que a adição da variável elevação de seja imprescindível no mapeamento de classes de vegetação florestal em áreas que possuam considerável variação altimétrica.

Yu et al., (2020) acrescentam que a topografia influencia grandemente a distribuição das espécies vegetais, de modo que diferentes altitudes, declives e orientações criam diversas condições ambientais específicas para o desenvolvimento de diferentes tipos de vegetação, além de usos antrópicos, conforme a disponibilidade de diferentes fatores como a radiação solar, temperatura, umidade e fertilidade do solo. Além do mais, Prodromou et al. (2024) frisam que a literatura existente tem demonstrado que a combinação de dados SAR e ópticos permite a identificação de diferentes características físicas e espectrais da cobertura do solo, potencialmente melhorando os resultados da classificação. Dessa forma os modelos de classificação propostos nesta pesquisa também se mostraram eficientes para identificação de diferentes usos e coberturas, além das formações florestais FED e CRD, conforme também evidenciado na pesquisa de Pavanelli et al. (2018).

Na presente pesquisa, os índices espectrais derivados das imagens Sentinel-2 NDVI, SAVI e NDWI tiveram importância significativa nos modelos de classificação ópticos e integrados. Pesquisas acerca dessa temática têm enfatizado a utilização do índices de vegetação, tais quais os que foram utilizados nesta pesquisa, pois possuem grande utilidade em tarefas de classificação de imagens, uma vez que estes fornecem informações adicionais às bandas espectrais, de modo que possibilita aos algoritmos de classificação suprimir parcialmente as influências como a iluminação solar, terreno

e reflectância do solo em dados de SR, e assim, obter dados de monitoramento da vegetação de forma mais confiável (Chaves; Picoli; Sanches, 2020; Tsai et al. 2018). Já o índice SAR RVI, recomendado por Prodromou et al. (2024) como sendo considerado importante para o monitoramento da vegetação por ser menos afetado por mudanças nas condições ambientais, como a umidade do solo, não obteve contribuição relativa de destaque nos modelos. Já a razão VV/VH, sugerida por Soudani et al. (2021), ocorreu dentre as cinco mais importantes em apenas um modelo da presente pesquisa.

O ranqueamento das variáveis relativamente mais importantes nos modelos de classificação demonstrou a utilidade das polarizações Sentinel-1, bandas espectrais do *Red-edge* e *Swir*, índices de vegetação e seus respectivos percentis como variáveis preditoras das classes mapeadas pelos algoritmos de classificação. As polarizações VV e VH do Sentinel-1 são reconhecidas por permitirem a coleta de informações estruturais, volumétricas e propriedades dielétricas dos objetos, na superfície terrestre, independentemente das condições atmosféricas (Ferla; Kuplich; Narvaes, 2025), de modo que podem ser utilizadas em complemento aos dados ópticos, os quais ficam sujeitos a ruídos como sombras e nuvens durante o período chuvoso (Sirro et al., 2018). Em estudo de classificação de fitofisionomias conduzido na região de Planaltina, no Distrito Federal, Haddad et al. (2023) verificaram que as informações advindas da estação seca dos produtos SAR tiveram melhor contribuição em modelo de classificação integrado com dados hiperespectrais. Além disso, esses autores acrescentam que tal resultado se relaciona com a significativa perda de folhas por espécies decíduas, de tal modo que esse processo pode ter proporcionado maior interação da banda C com pequenos galhos que ficam mais evidentes com a perda da folhagem.

Variáveis ópticas tendem a ter maior contribuição como variáveis preditoras em modelos de classificação integrados (Yu et al., 2020), no entanto variáveis SAR possuem informações complementares sobre a estrutura da vegetação e resposta do substrato, dessa forma, contribuindo com informações cruciais para discriminação de fitofisionomias savânicas (Haddad et al., 2023; Pavanelli et al., 2018).

Além disso, nesta pesquisa foi utilizada a técnica de adição de valores de percentis 25 e 75 à todas as bandas que compunham os conjuntos de dados utilizados, uma vez que constitui técnica amplamente utilizada como forma de aumentar o número de observações disponíveis por pixel (Symeonakis et al., 2018,

Xie et al., 2019), permitindo a adição de novas variáveis nos *stacks* para classificação. Dessa forma, tal técnica se mostrou eficaz, uma vez obteve significativa frequência na contribuição relativa dos modelos de classificação analisados com as maiores AGs. Em abordagem similar a da presente pesquisa, Prudente et al. (2023) classificaram a série de dados anuais Sentinel-2 de 2019, em área de estudo inserida no estado de Roraima e verificaram o percentil 75 da banda 11, e 25 da banda 5, dentre as cinco variáveis mais importantes do modelo, o qual foi classificado pelo RF. Dessa forma, conforme frisam Xie; Liu e Yang (2020), os percentis têm sido comumente utilizados como métrica temporal na classificação de cobertura da terra, uma vez que essas métricas podem capturar características fenológicas proeminentes, independentemente do período do ano especificado.

A análise comparativa de resultados de classificação de diferentes combinações temporais de dados de SR possibilita compreender melhor o desempenho de diferentes conjuntos de dados, bem como se o sistema de classificação proposto é confiável. Dessa forma, um sistema de classificação de uso e cobertura da terra mais eficiente pode ser proposto, considerando os objetivos da pesquisa e a capacidade das fontes de dados correspondentes a um determinado ecossistema florestal (Yu et al., 2020), o que evidencia a importância da abordagem empregada na presente pesquisa.

### 7.3. Limitações da abordagem desenvolvida e perspectivas futuras

A metodologia desenvolvida nesta pesquisa foi integralmente conduzida na plataforma GEE, cujas potencialidades de processamento, integração de dados e escalabilidade (Amani et al., 2020) foram fundamentais para a execução das análises propostas. Contudo, a aplicação da plataforma também evidenciou limitações que influenciam fluxos metodológicos baseados em ML, incluindo restrições no volume de dados para treinamento, redução do número de pixels disponíveis quando múltiplas variáveis são integradas, e em algumas ocasiões, dificuldades na manipulação de dados referentes a grandes extensões espaciais. Embora o GEE represente uma plataforma robusta para análises geoespaciais em larga escala, tais restrições podem impor condicionantes metodológicos e devem ser consideradas para a condução de novas pesquisas.

Além disso, por se tratar de uma investigação em escala local, os resultados refletem condicionantes ambientais e espectro-temporais específicos da área de estudo, limitando extrapolações diretas para outras regiões. Nesse sentido, estudos futuros em escalas regionais e em outros biomas são necessários para avaliar a robustez, a transferibilidade e o potencial de generalização das abordagens propostas.

Considerando que a ocorrência dos diversos tipos florestais depende de diversos fatores ambientais (Yu et al., 2020), oportunidades de pesquisas futuras podem investigar novos métodos para a adição de informações ambientais, a exemplo da geomorfologia, geologia e pedologia (Zeferino et al., 2020) e avaliar de que modo estas variáveis podem influenciar os resultados de modelos de classificação baseados em abordagem *Machine Learning*. Além disso, recomenda-se que sejam testados diferentes métodos de processamento, a exemplo da utilização da média (Vizzari, 2022), desvio padrão (Silva et al., 2021), dentre outros filtros estatísticos (Becker et al., 2021) como estatística-resumo para as séries temporais de dados de SR, de modo a aprimorar o conhecimento científico acerca das técnicas de classificação para FED. Adicionalmente, conforme discutido em pesquisas anteriores (Saimun; Rahman, 2025, Maxwell et al., 2018), não há como afirmar categoricamente que há um classificador superior outro devido a uma série fatores como a natureza dos dados de treinamento, classes-alvo e variáveis preditoras, dessa forma sendo recomendado que em futuras pesquisas, se possível, que múltiplos classificadores sejam testados para determinar qual fornece a classificação ideal para uma tarefa específica.

## 8. CONSIDERAÇÕES FINAIS

Esta pesquisa demonstrou que a integração entre dados SAR e ópticos, associada ao algoritmo GTB e a composições anuais, representa a abordagem mais promissora para o mapeamento de FED no Vão do Paranã. Como principal achado, evidenciou-se que a sazonalidade e o uso de variáveis auxiliares como a elevação são fatores decisivos para aumentar a confiabilidade da identificação dessa fitofisionomia e demais classes presentes na área de estudo. Além do avanço metodológico, os resultados reforçam o potencial de abordagens multissensores e de *Machine Learning* para o monitoramento da FED, ao mesmo tempo em que a revisão sistemática revelou lacunas e oportunidades para novas pesquisas, sobretudo com integração de sensores SAR e hiperespectrais, bem como métodos de *Deep Learning*. Esses achados contribuem tanto para o avanço do conhecimento acerca do mapeamento de FEDs, quanto para o subsídio às estratégias de conservação desse ecossistema, o qual, notadamente, apresenta grande relevância associada a biodiversidade e provisão de de variados serviços ecossistêmicos às comunidades que nele habitam.

## 9. REFERÊNCIAS

- AGRAWAL, S.; KHAIRNAR, G. B. A comparative assessment of remote sensing imaging techniques: optical, sar and lidar. *In: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Dhulikhel, Nepal: ISPRS, 2019, v. XLII-5/W3, p. 1–6.
- ALBA, E.; ALEXANDRE, M. L. S.; MARCHESAN, J.; *et al.* Comparação entre Algoritmos de Aprendizado de Máquina para a Identificação de Floresta Tropical Sazonalmente Seca. **Anuário do Instituto de Geociências**, v. 45, p. 1–10, 2022.
- ALENCAR, A.; SHIMBO, J. Z.; LENTI, F.; *et al.* 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.
- AMANI, M.; GHORBANIAN, A.; AHMADI, S. A.; *et al.* Google Earth Engine Cloud Computing Platform for Remote Sensing Big Data Applications: A Comprehensive Review. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 13, p. 5326–5350, 2020.
- ARAÚJO, J. A.; GALVÃO, L. S.; DALAGNOL, R. Sensitivity of hyperspectral vegetation indices to rainfall seasonality in the Brazilian savannahs: an analysis using PRISMA data. **Remote Sensing Letters**, v. 14, n. 3, p. 277–287, 2023.
- ARRUDA, M. B.; PROENÇA, C. E. B.; RODRIGUES, S. C.; *et al.* Ecorregiões, unidades de conservação e representatividade ecológica do bioma Cerrado. *In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. (Orgs.). Cerrado: Ecologia e Flora*. Brasília: Embrapa Cerrados, 2008, v. 1, p. 229–271.
- AURUP, G. M. M. **User Preference Extraction from Bio-Signals: An Experimental Study**. Dissertação de mestrado em Applied Sciences, Concordia University, Montreal, Canadá, 2011.
- BECKER, W. R.; LÓ, T. B.; JOHANN, J. A.; *et al.* Statistical features for land use and land cover classification in Google Earth Engine. **Remote Sensing Applications: Society and Environment**, v. 21, p. 100459, 2021.
- BENDINI, H. N.; FONSECA, L. M. G.; MATOSAK, B. M.; *et al.* Evaluating the Separability Between Dry Tropical Forests and Savanna Woodlands in the Brazilian Savanna Using Landsat Dense Image Time Series and Artificial Intelligence. *In: International archives of the photogrammetry, remote sensing and spatial information sciences*. Nice, France: ISPRS, 2022, v. XLIII-B3-2022, p. 841–847.
- CALVO-RODRIGUEZ, S.; SANCHEZ-AZOFEIFA, A. G.; DURAN, S. M.; *et al.* Assessing ecosystem services in Neotropical dry forests: a systematic review. **Environmental Conservation**, v. 44, n. 1, p. 34–43, 2017.
- CARVALHO JÚNIOR, O. A. Aplicações e perspectivas do sensoriamento remoto para o mapeamento de áreas inundáveis. **Revista de Geografia**, v. 35, n. 4, p. 412–431, 2018.

CARVALHO JÚNIOR, O. A.; HERMUCHE, P. M.; GUIMARÃES, R. F. Identificação regional da Floresta Estacional Decidual na bacia do Rio Paranã a partir da análise multitemporal de imagens MODIS. **Revista Brasileira de Geofísica**, v. 24, n. 3, p. 319–332, 2006.

CHAVES, M.; PICOLI, M.; SANCHES, I. Recent Applications of Landsat 8/OLI and Sentinel-2/MSI for Land Use and Land Cover Mapping: A Systematic Review. **Remote Sensing**, v. 12, n. 18, p. 3062, 2020.

CHEN, R.; YANG, H.; YANG, G.; *et al.* Land-Use Mapping with Multi-Temporal Sentinel Images Based on Google Earth Engine in Southern Xinjiang Uygur Autonomous Region, China. **Remote Sensing**, v. 15, n. 16, p. 3958, 2023.

COELHO, M.; FERNANDES, G. W.; SANCHEZ-AZOFEIFA, A. Brazilian Tropical Dry Forest on Basalt and Limestone Outcrops: Status of Knowledge and Perspectives. *In*: SANCHEZ-AZOFEIFA, A.; POWERS, J. S.; FERNANDES, G. W.; *et al* (Orgs.). **Tropical Dry Forests in the Americas: Ecology, Conservation and Management**. Boca Raton, Florida: CRC Press, 2013, p. 55–68.

CONGALTON, R. G.; GREEN, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices, Third Edition**. 3. ed. Boca Raton, Florida: CRC Press, 2019.

COSTA, V. L.; FREITAS, M. W. Classificação de estágios sucessionais da Floresta Estacional Semidecídua utilizando dados Sentinel-1-2 e SRTM no Google Earth Engine. **Ciência Florestal**, v. 34, n. 2, p. e68716, 2024.

ESPIRITO-SANTO, M. M.; FAGUNDES, M.; NUNES, Y. R. F.; *et al.* Bases para a conservação e uso sustentável das florestas estacionais deciduais brasileiras: a necessidade de estudos multidisciplinares. **Unimontes Científica**, v. 8, n. 1, p. 13–22, 2006.

ESPÍRITO-SANTO, M. M.; SEVILHA, A. C.; ANAYA, F. C.; *et al.* Sustainability of tropical dry forests: Two case studies in southeastern and central Brazil. **Forest Ecology and Management**, v. 258, n. 6, p. 922–930, 2009.

FARIA, K. M. S.; SILVA, E. V. Dinâmica Das Paisagens Antropogênicas Na Microrregião Do Vão Do Paranã (GO). **Revista Geográfica Acadêmica**, v. 14, n. 2, p. 141–152, 2020.

FARRICK, K. K.; BRANFIREUN, B. A. Left high and dry: a call to action for increased hydrological research in tropical dry forests. **Hydrological Processes**, v. 27, n. 22, p. 3254–3262, 2013.

FERLA, A. K.; KUPLICH, T. M.; NARVAES, I. S. Utilização do classificador Random Forest para Classificação do Uso e Cobertura da Terra a partir de Dados Sentinel 1 e 2 em região campestre no bioma Mata Atlântica. **Geografia Ensino & Pesquisa**, v. 29, p. e87967, 2025.

FRIEDL, M.; SULLA-MENASHE, D. MODIS/Terra+Aqua Land Cover Type Yearly L3

Global 500m SIN Grid V061. Disponível em: <<https://www.earthdata.nasa.gov/data/catalog/lpcloud-mcd12q1-061>>. Acesso em: 11 nov. 2025.

FUNK, C.; PETERSON, P.; LANDSFELD, M.; *et al.* The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. **Scientific Data**, v. 2, n. 1, p. 150066, 2015.

GANEM, K. A.; XUE, Y.; RODRIGUES, A. A.; *et al.* Mapping South America's Drylands through Remote Sensing—A Review of the Methodological Trends and Current Challenges. **Remote Sensing**, v. 14, n. 3, p. 736, 2022.

GAO, Y.; SOLÓRZANO, J. V.; ESTOQUE, R. C.; *et al.* Tropical Dry Forest Dynamics Explained by Topographic and Anthropogenic Factors: A Case Study in Mexico. **Remote Sensing**, v. 15, n. 5, p. 1471, 2023.

GOOGLE. Earth Engine Data Catalog. Disponível em: <<https://developers.google.com/earth-engine/datasets>>. Acesso em: 30 nov. 2025.

GORELICK, N.; HANCHER, M.; DIXON, M.; *et al.* Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 2017.

GUIMARAES, R.; DE CARVALHO JR., O.; HERMUCHE, P.; *et al.* Regional Identification of the Deciduous Forests of Brazil Central Using NDVI Seasonal Variations of the Sensor MODIS and Digital Elevation Model. *In*: **2006 IEEE International Symposium on Geoscience and Remote Sensing**. Denver, CO, USA: IEEE, 2006, p. 3607–3610.

GYAMFI-AMPADU, E.; GEBRESLASIE, M.; MENDOZA-PONCE, A. Mapping natural forest cover using satellite imagery of Nkandla forest reserve, KwaZulu-Natal, South Africa. **Remote Sensing Applications: Society and Environment**, v. 18, p. 100302, 2020.

HADDAD, I.; GALVÃO, L. S.; BREUNIG, F. M.; *et al.* Atributos Temporais Derivados Da Combinação De Dados PlanetScope E Sentinel-1 Para Classificação De Savanas Brasileiras. *In*: **Anais do XX Simpósio Brasileiro de Sensoriamento Remoto**. Florianópolis: INPE, 2023.

HERMUCHE, P. M. **Modelagem Da Paisagem Da Floresta Estacional Decidual No Vão Do Paranã, Goiás**. Tese de Doutorado em Geografia, Universidade Federal de Goiás, Goiania, 2010.

HERMUCHE, P. M.; FELFILI, J. M. Relação entre NDVI e florística em fragmentos de Floresta Estacional Decidual no Vale do Paranã, Goiás. **Ciência Florestal**, v. 21, n. 1, p. 41–52, 2011.

HERMUCHE, P. M.; FERREIRA, N. C.; SANO, E. E. Proposta metodológica para elaboração de mapa de tendência de uso da terra no Vão do Paranã, Goiás, baseada em condicionantes ambientais e sócio-econômicos. *In*: **Anais XIV Simpósio Brasileiro de Sensoriamento Remoto**. Natal, Brasil: INPE, 2009, p.

5873–5880.

HERMUCHE, P. M.; SANO, E. Identificação da floresta estacional decidual no vão do paranã, estado de goiás, a partir da análise da reflectância acumulada de imagens do sensor etm+/landsat-7. **Revista Brasileira de Cartografia**, v. 63, n. 3, p. 415–425, 2011.

HESKETH, M.; SANCHEZ-AZOFEIFA, A. A Review of Remote Sensing of Tropical Dry Forests. In: SANCHEZ-AZOFEIFA, A.; POWERS, J. S.; FERNANDES, G. W.; *et al* (Orgs.). **Tropical Dry Forests in the Americas: Ecology, Conservation and Management**. Boca Raton, Florida: CRC Press, 2013, p. 83–100.

HIGGINBOTTOM, T. P.; SYMEONAKIS, E.; MEYER, H.; *et al*. Mapping fractional woody cover in semi-arid savannahs using multi-seasonal composites from Landsat data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 139, p. 88–102, 2018.

HUECHACONA-RUIZ, A. H.; DUPUY, J. M.; SCHWARTZ, N. B.; *et al*. Mapping Tree Species Deciduousness of Tropical Dry Forests Combining Reflectance, Spectral Unmixing, and Texture Data from High-Resolution Imagery. **Forests**, v. 11, n. 11, p. 1234, 2020.

IBGE. Banco de Dados e Informações Ambientais. Disponível em: <<https://bdiaweb.ibge.gov.br/#/consulta/pesquisa>>. Acesso em: 22 mar. 2026.

JOSHI, N.; BAUMANN, M.; EHAMMER, A.; *et al*. A Review of the Application of Optical and Radar Remote Sensing Data Fusion to Land Use Mapping and Monitoring. **Remote Sensing**, v. 8, n. 1, p. 70, 2016.

LECHNER, A. M.; FOODY, G. M.; BOYD, D. S. Applications in Remote Sensing to Forest Ecology and Management. **One Earth**, v. 2, n. 5, p. 405–412, 2020.

LI, R.; FANG, P.; XU, W.; *et al*. Classifying Forest Types over a Mountainous Area in Southwest China with Landsat Data Composites and Multiple Environmental Factors. **Forests**, v. 13, n. 1, p. 135, 2022.

MAPBIOMAS. Projeto Map Biomas - Coleção 10 da Série Anual de Mapas de Cobertura e Uso da Terra do Brasil. Disponível em: <<https://brasil.mapbiomas.org/colecoes-mapbiomas/>>. Acesso em: 30 nov. 2025.

MAXWELL, A. E.; WARNER, T. A.; FANG, F. Implementation of machine-learning classification in remote sensing: an applied review. **International Journal of Remote Sensing**, v. 39, n. 9, p. 2784–2817, 2018.

NASA JPL. NASADEM Merged DEM Global 1 arc second V001. Disponível em: <<https://www.earthdata.nasa.gov/data/catalog/lpcloud-nasadem-hgt-001>>. Acesso em: 23 mar. 2026.

NASIRI, V.; DELJOUEI, A.; MORADI, F.; *et al*. Land Use and Land Cover Mapping Using Sentinel-2, Landsat-8 Satellite Images, and Google Earth Engine: A Comparison of Two Composition Methods. **Remote Sensing**, v. 14, n. 9, p. 1977,

2022.

NOLASCO, M.; BALZARINI, M. Assessment of temporal aggregation of Sentinel-2 images on seasonal land cover mapping and its impact on landscape metrics. **Environmental Monitoring and Assessment**, v. 197, n. 2, p. 142, 2025.

NUNES, F. G.; SANTOS, A. M. Uso e cobertura da terra e efetividade das normativas legais em unidades de conservação no estado de Goiás - Brasil. **Boletim de Geografia**, v. 40, p. 170–185, 2022.

OLIVEIRA, M. T.; CASSOL, H. L. G.; GANEM, K. A.; *et al.* Mapeamento da Vegetação do Cerrado – Uma Revisão das Iniciativas de Sensoriamento Remoto. **Revista Brasileira de Cartografia**, v. 72, p. 1250–1274, 2020.

PAVANELLI, J. A. P.; SANTOS, J. R.; GALVÃO, L. S.; *et al.* Palsar-2/Alos-2 and Oli/Landsat-8 Data Integration for Land Use and Land Cover Mapping in Northern Brazilian Amazon. **Boletim de Ciências Geodésicas**, v. 24, n. 2, p. 250–269, 2018.

PENNINGTON, R. T.; PRADO, D. E.; PENDRY, C. A. Neotropical seasonally dry forests and Quaternary vegetation changes. **Journal of Biogeography**, v. 27, n. 2, p. 261–273, 2000.

PEREIRA, B. S.; VENTUROLI, F.; CARVALHO, F. A. Florestas Estacionais No Cerrado: Uma Visão Geral. **Pesquisa Agropecuária Tropical**, v. 41, n. 3, p. 446–455, 2011.

PHAN, T. N.; KUCH, V.; LEHNERT, L. W. Land Cover Classification using Google Earth Engine and Random Forest Classifier—The Role of Image Composition. **Remote Sensing**, v. 12, n. 15, p. 2411, 2020.

PORTILLO-QUINTERO, C.A.; SÁNCHEZ-AZOFEIFA, G.A. Extent and conservation of tropical dry forests in the Americas. **Biological Conservation**, v. 143, n. 1, p. 144–155, 2010.

PRODROMOU, M.; THEOCHARIDIS, C.; GITAS, I. Z.; *et al.* Forest Habitat Mapping in Natura2000 Regions in Cyprus Using Sentinel-1, Sentinel-2 and Topographical Features. **Remote Sensing**, v. 16, n. 8, p. 1373, 2024.

PRUDENTE, V. H. R.; SKAKUN, S.; OLDONI, L. V.; *et al.* Multisensor approach to land use and land cover mapping in Brazilian Amazon. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 189, p. 95–109, 2022.

PRUDENTE, V. H. R.; SILVA, N. R. F.; GARCIA, A.D.B; *et al.* Land Use and Land Cover Classification Using a Sar Optical Cloud Computer Approach in Southern of Roraima. *In: Anais do XX Simpósio Brasileiro de Sensoriamento Remoto*. Florianópolis: INPE, 2023, p. 2701–2704.

RIBEIRO, A. R.; MERINO, E. R. Revisão Sistemática de Literatura sobre o Uso de Sensoriamento Remoto e Algoritmos Baseados em Machine Learning no Mapeamento de Florestas Tropicais Secas. **Revista Brasileira de Cartografia**, v. 77, 2025.

RIBEIRO, J. F.; WALTER, B. M. T. As Principais Fitofisionomias do Bioma Cerrado. *In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. (Orgs.). Cerrado: Ecologia e Flora*. Brasília: Embrapa Cerrados, 2008, v. 1, p. 151–212.

SAIMUN, Md. R. S.; RAHMAN, M. M. A comprehensive review of tree cover mapping using satellite sensor data. **Discover Geoscience**, v. 3, n. 1, p. 90, 2025.

SANO, E. E.; RODRIGUES, A. A.; MARTINS, E. S.; *et al.* Cerrado ecoregions: A spatial framework to assess and prioritize Brazilian savanna environmental diversity for conservation. **Journal of Environmental Management**, v. 232, p. 818–828, 2019.

SANTOS, L. A. C.; MIRANDA, S. C.; SILVA NETO, C. M. Fitofisionomias do Cerrado: definições e tendências. **Élisée - Revista de Geografia da UEG**, v. 9, n. 2, p. 1–32, 2020.

SAVITHA, C.; TALARI, R. Evaluating the performance of random forest, support vector machine, gradient tree boost, and CART for improved crop-type monitoring using greenest pixel composite in Google Earth Engine. **Environmental Monitoring and Assessment**, v. 197, n. 4, p. 437, 2025.

SCHRÖDER, J. M.; RODRÍGUEZ, L. P.; GÜNTER, S. Research trends: Tropical dry forests: The neglected research agenda? **Forest Policy and Economics**, v. 122, p. 102333, 2021.

SILVA, A. G. P.; CREMON, E. H.; BOGGIONE, G. A.; *et al.* Integração de imagens Orbitais Ópticas e SAR Com Processamento em Nuvem no Mapeamento da Cobertura da Terra no Cerrado. **Geoaraguia**, v. 11, n. Esp. Geotecnologias, p. 85–106, 2021.

SIRRO, L.; HÄME, T.; RAUSTE, Y.; *et al.* Potential of Different Optical and SAR Data in Forest and Land Cover Classification to Support REDD+ MRV. **Remote Sensing**, v. 10, n. 6, p. 942, 2018.

SMITH, W. K.; DANNENBERG, M. P.; YAN, D.ong; *et al.* Remote sensing of dryland ecosystem structure and function: Progress, challenges, and opportunities. **Remote Sensing of Environment**, v. 233, p. 111401, 2019.

SOUDANI, K.; DELPIERRE, N.; BERVEILLER, D.; *et al.* Potential of C-band Synthetic Aperture Radar Sentinel-1 time-series for the monitoring of phenological cycles in a deciduous forest. **International Journal of Applied Earth Observation and Geoinformation**, v. 104, p. 102505, 2021.

SOUZA, F. C. R.; SALGADO, A. A. R.; SILVA, T. A.; *et al.* Caracterização de depressões fechadas no vão do Paranã, a oeste da Serra Geral de Goiás. **Geografia Ensino & Pesquisa**, v. 22, p. 20, 2018.

SRIVASTAVA, A.; BHARADWAJ, S.; DUBEY, R.; *et al.* Mapping Vegetation and Measuring the Performance of Machine Learning Algorithm in Lulc Classification in the Large Area Using Sentinel-2 and Landsat-8 Datasets of Dehradun as a Test

Case. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLIII-B3-2022, p. 529–535, 2022.

SYMEONAKIS, E.; HIGGINBOTTOM, T.; PETROULAKI, K.; *et al.* Optimisation of Savannah Land Cover Characterisation with Optical and SAR Data. **Remote Sensing**, v. 10, n. 4, p. 499, 2018.

TSAI, Y. H.; STOW, D.; CHEN, H. L.; *et al.* Mapping Vegetation and Land Use Types in Fanjingshan National Nature Reserve Using Google Earth Engine. **Remote Sensing**, v. 10, n. 6, p. 1–14, 2018.

VIZZARI, M. PlanetScope, Sentinel-2, and Sentinel-1 Data Integration for Object-Based Land Cover Classification in Google Earth Engine. **Remote Sensing**, v. 14, n. 11, p. 2628, 2022.

VOROVENCII, I. Assessing Various Scenarios of Multitemporal Sentinel-2 Imagery, Topographic Data, Texture Features, and Machine Learning Algorithms for Tree Species Identification. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 17, p. 15373–15392, 2024.

WAN, Z.; HOOK, S.; HULLEY, G. MODIS/Terra Land Surface Temperature/Emissivity 8-Day L3 Global 1km SIN Grid V061. Disponível em: <<https://www.earthdata.nasa.gov/data/catalog/lpcloud-mod11a2-061>>. Acesso em: 22 mar. 2026.

WAŚNIEWSKI, A.; HOŚCIŁO, A.; ZAGAJEWSKI, B.; *et al.* Assessment of Sentinel-2 Satellite Images and Random Forest Classifier for Rainforest Mapping in Gabon. **Forests**, v. 11, n. 9, p. 941, 2020.

XIE, S.; LIU, L.; YANG, J. Time-Series Model-Adjusted Percentile Features: Improved Percentile Features for Land-Cover Classification Based on Landsat Data. **Remote Sensing**, v. 12, n. 18, p. 3091, 2020.

XIE, S.; LIU, L.; ZHANG, X.; *et al.* Automatic Land-Cover Mapping using Landsat Time-Series Data based on Google Earth Engine. **Remote Sensing**, v. 11, n. 24, p. 3023, 2019.

YU, X.; LU, D.; JIANG, X.; *et al.* Examining the Roles of Spectral, Spatial, and Topographic Features in Improving Land-Cover and Forest Classifications in a Subtropical Region. **Remote Sensing**, v. 12, n. 18, p. 2907, 2020.

ZANAGA, D.; VAN DE KERCHOVE, R.; DE KEERSMAECKER, W.; *et al.* ESA WorldCover 10 m 2020 v100. Disponível em: <<https://zenodo.org/record/5571936>>. Acesso em: 30 nov. 2025.

ZEFERINO, L. B.; SOUZA, L. F. T.; AMARAL, C. H.; *et al.* Does environmental data increase the accuracy of land use and land cover classification? **International Journal of Applied Earth Observation and Geoinformation**, v. 91, p. 102128, 2020.

ZENG, H.; WU, B.; WANG, S.; *et al.* A Synthesizing Land-cover Classification

Method Based on Google Earth Engine: A Case Study in Nzhelele and Levhuvu Catchments, South Africa. **Chinese Geographical Science**, v. 30, n. 3, p. 397–409, 2020.