



Revisão Sistemática de Literatura sobre o Uso de Sensoriamento Remoto e Algoritmos Baseados em *Machine Learning* no Mapeamento de Florestas Tropicais Secas

Systematic Literature Review on the Use of Remote Sensing and Machine Learning-Based Algorithms in Tropical Dry Forest Mapping

Anderson Rodrigues Ribeiro ¹ e Eder Renato Merino ²

¹ Universidade de Brasília, Brasília, Brasil. andersonhcp22@gmail.com.

ORCID: <https://orcid.org/0009-0004-8556-1620>

² Universidade de Brasília, Brasília, Brasil. eder.merino@unb.br.

ORCID: <https://orcid.org/0000-0003-2155-8620>

Recebido: 11.2024 | Aceito: 03.2025

Resumo: As florestas tropicais secas são um ecossistema florestal notadamente marcado pela sazonalidade climática e predomínio de espécies arbóreas que apresentam acentuada deciduidade durante a estação seca e grande perenidade durante a estação úmida. Esses ambientes abrigam uma rica diversidade de fauna e flora, desempenhando um papel crucial na qualidade de vida de milhões de pessoas ao fornecer serviços ecossistêmicos essenciais. Devido a sua ocorrência em solos férteis, tem sido crescente os registros de pressões antrópicas sobre seus remanescentes florestais para conversão em agricultura. Por essa razão, tem sido crescente a demanda por ações de monitoramento ambiental. Neste sentido, tem se destacado na literatura recente a utilização de métodos de *Machine Learning* (ML) aplicados ao sensoriamento remoto de florestas tropicais secas. Assim, o presente estudo propôs, por meio de uma revisão sistemática de literatura, uma avaliação quantitativa dos principais sensores remotos e algoritmos de ML empregados nos últimos anos, de modo que foi possível obter uma visão geral dos métodos atuais, bem como temas promissores para futuras pesquisas. Como principais resultados, verificou-se que as principais abordagens têm priorizado a utilização do algoritmo *Random Forest* e dados provenientes de sensores ópticos. Com a realização desta revisão, observou-se que oportunidades de pesquisas futuras encontram-se na análise da utilização integrada de sensores SAR e ópticos, bem como em avaliação comparativa entre diferentes algoritmos de ML, de maneira que possam ser avaliados novos métodos para o progresso no monitoramento e conservação de florestas tropicais secas.

Palavras-chave: Sazonalidade. Imagens de Satélite. Classificação. Bibliometria. Inteligência Artificial.

Abstract: Tropical dry forests are a forest ecosystem notably marked by climatic seasonality and predominance of tree species that present marked deciduousness during the dry season and great perennity during the wet season. These environments are home to a rich diversity of fauna and flora, playing a crucial role in the quality of life of millions of people by providing essential ecosystem services. Due to their occurrence in fertile soils, there have been increasing records of anthropic pressures on their forest remnants for conversion to agriculture. For this reason, the demand for environmental monitoring actions has been growing. In this sense, the use of Machine Learning (ML) methods applied to remote sensing of tropical dry forests has stood out in recent literature. Thus, the present study proposed, through a systematic literature review, a quantitative evaluation of the main remote sensing and ML algorithms used in recent years, so that it was possible to obtain an overview of current methods, as well as promising topics for future research. As main results, it was found that the main approaches have prioritized the use of the Random Forest algorithm and data from optical sensors. By carrying out this review, it was observed that opportunities for future research lie in the analysis of the integrated use of SAR and optical sensors, as well as in comparative evaluation between different ML algorithms, so that new methods can be evaluated for progress in the monitoring and conservation of dry tropical forests.

Keywords: Seasonality. Satellite Imagery. Classification. Bibliometrics. Artificial Intelligence.

1 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 km² 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-temporalmemente 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 acurárias 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.

2 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,

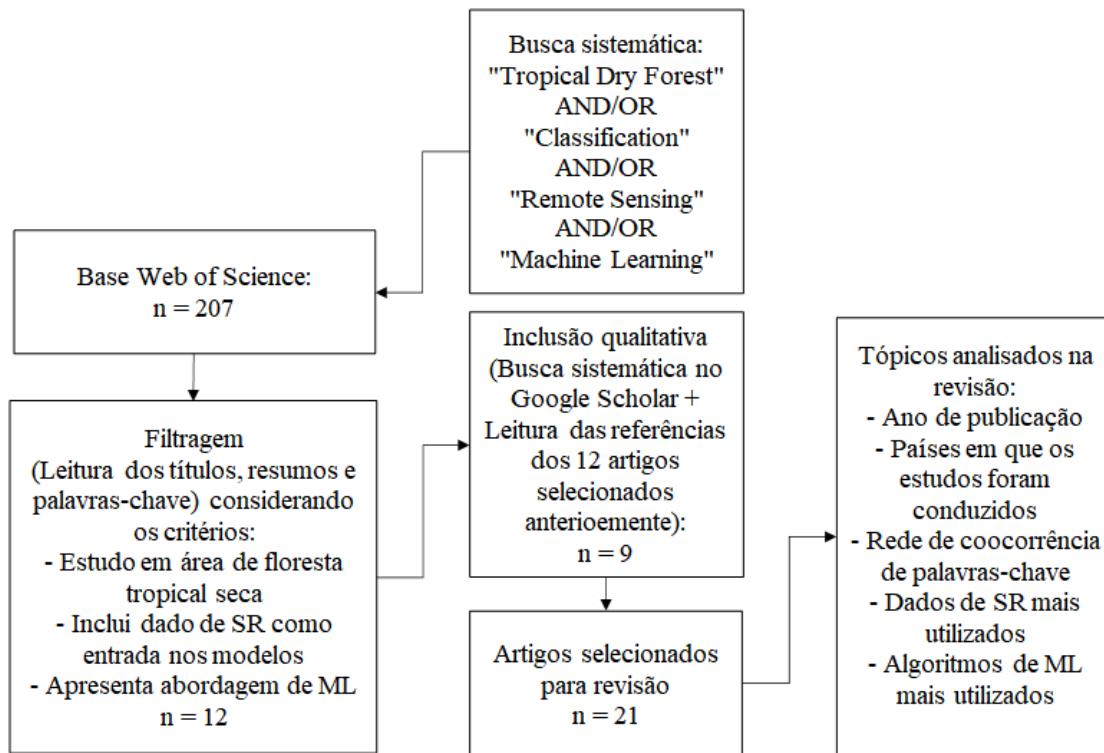
considerando o intervalo temporal de 2014 e 2024, assim, obtendo-se uma visão geral das principais aplicações no contexto da última década.

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 visualizado na Figura 1.

Figura 1 – Fluxo metodológico da revisão.



Fonte: Os autores (2024).

3 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.

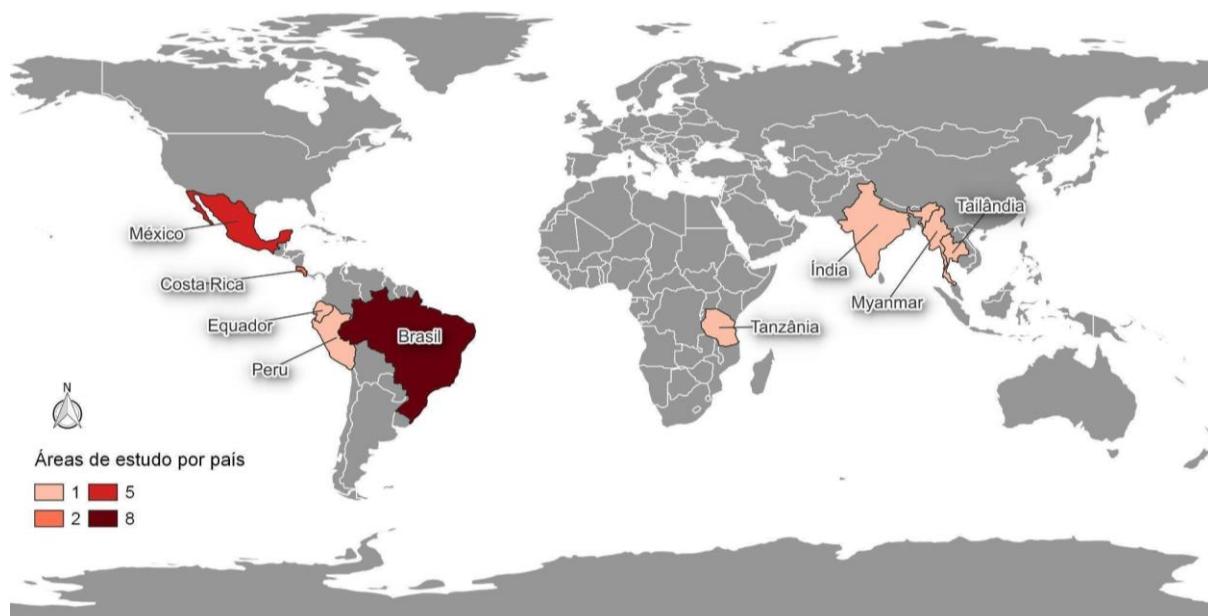
A partir da Figura 2 é possível observar que a região Neotropical tem tido grande destaque na quantidade de áreas estudadas, sendo Brasil e México os países que possuem mais áreas de estudo investigando florestas tropicais secas por métodos de ML baseado em SR, conforme os critérios adotados para a seleção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

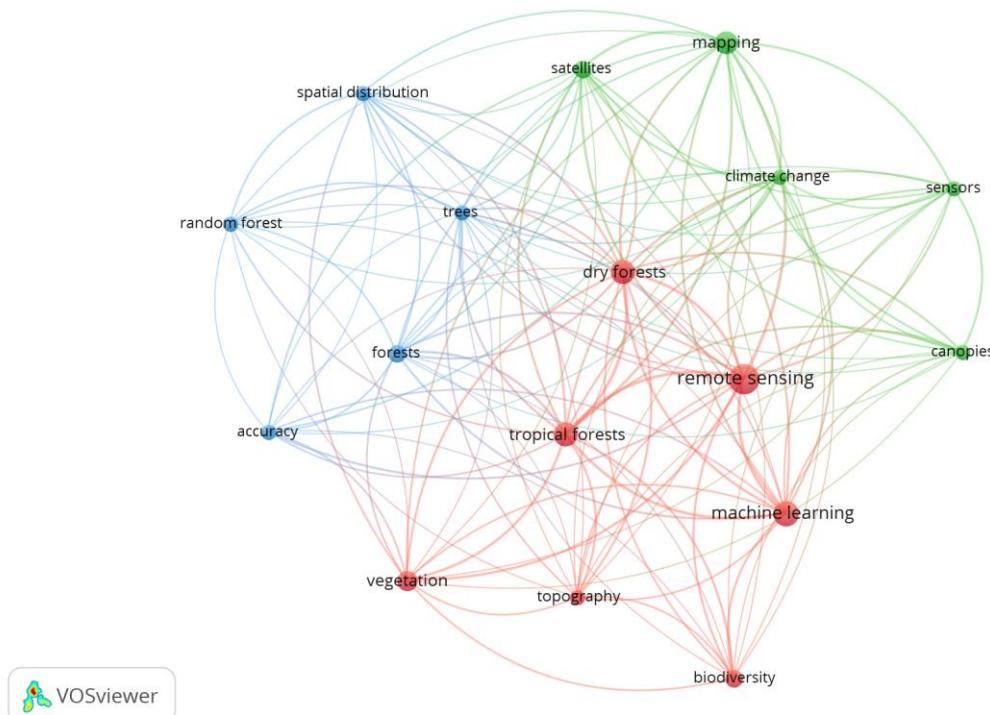
Figura 2 – Países em que as áreas de estudo foram identificadas nas publicações.



Fonte: Os autores (2024).

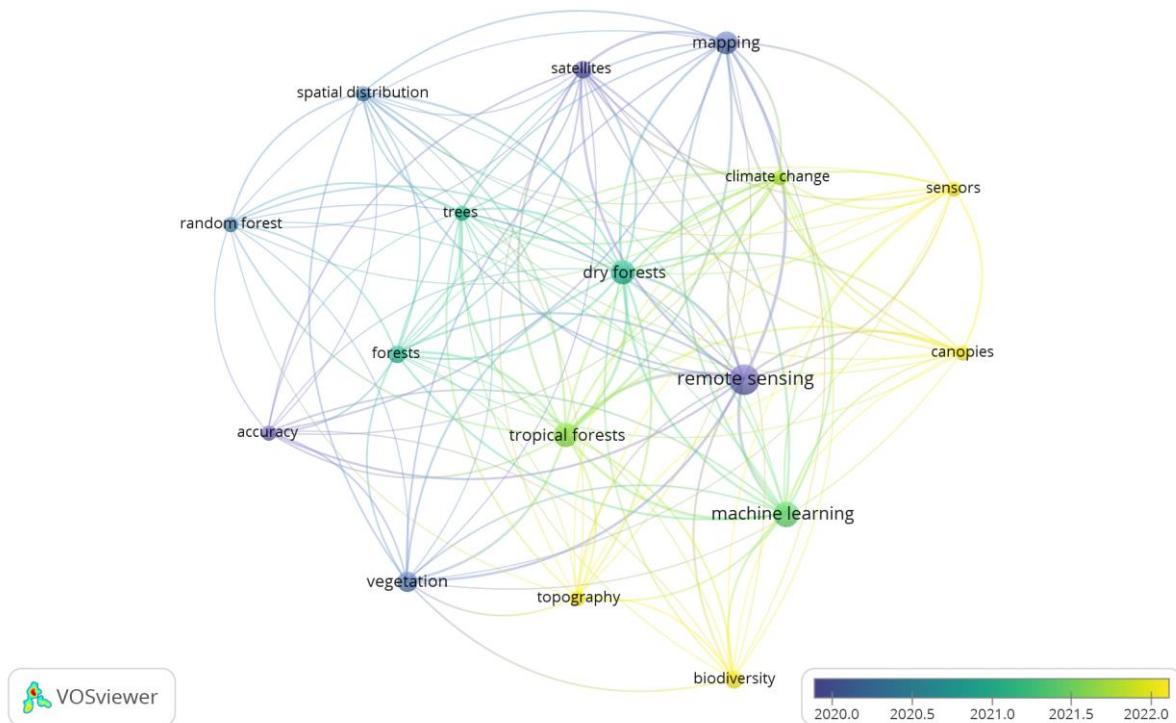
Na Figura 3 é possível observar o agrupamento de palavras-chave com pelo menos 3 ocorrências nos artigos revisados, enquanto na Figura 4 são apresentados os agrupamentos conforme o ano de publicação dos termos. Como temas emergentes associados às publicações revisadas estão incluídas análises de acurácia (*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).

3.1 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).

3.2 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).

4 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 sensitividade 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 acuráncias 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.

5 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 reproduzibilidade. 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.

Agradecimentos

Os autores agradecem ao LSIE (Laboratório de Sistemas de Informações Espaciais), do departamento

de Geografia da Universidade de Brasília, pelos recursos computacionais disponibilizados para a realização desta pesquisa. Os autores também estendem os agradecimentos aos revisores anônimos pelas valiosas sugestões e comentários que auxiliaram na elaboração da versão final deste manuscrito.

Contribuição dos Autores

A. R. R.: Conceptualização, Curadoria dos dados, Análise formal, Metodologia e Redação. E. R. M.: Conceptualização, Metodologia e Supervisão.

Conflitos de Interesse

Os autores declaram que não há conflitos de interesse.

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
- 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 forest: 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 vôlei do paraná, 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
- 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>

Biografia do autor principal



Anderson Rodrigues Ribeiro nasceu em Brasília (DF), no ano de 1997. É licenciado e bacharel em Geografia pela UnB (Universidade de Brasília), com ênfase em geoprocessamento e análise ambiental. Durante a graduação, estagiou ao longo de 15 meses no LSIE (Laboratório de Sistemas de Informações Espaciais), do departamento de Geografia da UnB. Atualmente é mestrando no Programa de Pós-Graduação em Geografia pela UnB. Interesses de pesquisa centram-se na utilização técnicas de Sensoriamento Remoto para caracterização da dinâmica da paisagem.



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