



**UNIVERSIDADE DE BRASÍLIA – UNB
INSTITUTO DE CIÊNCIAS HUMANAS – IH
DEPARTAMENTO DE GEOGRAFIA – GEA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA**

**ANÁLISE COMPARATIVA DE ARQUITETURAS DE APRENDIZAGEM
PROFUNDA EM SÉRIES TEMPORAIS DE IMAGENS DE SATÉLITE PARA A
CLASSIFICAÇÃO E DETECÇÃO DE *Tithonia diversifolia* E *Pteridium
arachnoideum* NO CERRADO**

Leandro de Arruda Bruno

Dissertação de Mestrado

Orientador: Osmar Abílio de Carvalho Junior

Coorientadora: Potira Meirelles Hermuche

Brasília - DF, 29 de agosto de 2025



**Universidade de Brasília - UnB
Instituto de Ciências Humanas – IH
Departamento de Geografia – GEA
Programa de Pós-Graduação em Geografia**

**ANÁLISE COMPARATIVA DE ARQUITETURAS DE APRENDIZAGEM
PROFUNDA EM SÉRIES TEMPORAIS DE IMAGENS DE SATÉLITE PARA A
CLASSIFICAÇÃO E DETECÇÃO DE *Tithonia diversifolia* E *Pteridium
arachnoideum* NO CERRADO**

**Comparative Analysis of Deep Learning Architectures on Satellite Image
Time Series for the Classification and Detection of *Tithonia diversifolia*
and *Pteridium arachnoideum* in the Cerrado**

LEANDRO DE ARRUDA BRUNO

Dissertação de Mestrado submetida ao Departamento de Geografia da Universidade de Brasília, como parte dos requisitos necessários para a obtenção do Grau de Mestre em Geografia, área de concentração Geoprocessamento, opção Acadêmica.

Aprovado por:

Osmar Abílio de Carvalho Junior, Doutor (Universidade de Brasília – UnB)
(Orientador)

Cristiane Batista Salgado, Doutor (Instituto Federal de Brasília - IFB)
(Examinador Externo)

Jaeter Waldemar Maciel Correa Santos, Doutor (Universidade Federal de Rondonópolis - IFR)
(Examinador Externo)

Brasília-DF, 29 de agosto de 2025

Sumário

1. INTRODUÇÃO	1
2. MATERIAIS E MÉTODOS	7
2.1 ÁREA DE ESTUDO	7
2.2 AQUISIÇÃO DE IMAGENS	9
2.3 AQUISIÇÃO DE AMOSTRAS.....	10
2.4 ALGORITMOS DE CLASSIFICAÇÃO.....	11
2.5 AVALIAÇÃO DE PRECISÃO	15
3. RESULTADOS.....	16
3.1 COMPORTAMENTO ESPECTRO TEMPORAL DOS ALVOS.....	16
3.2 DESEMPENHO COMPARATIVO DOS MODELOS DE APRENDIZAGEM PROFUNDA.....	22
3.3 MATRIZES DE CONFUSÃO E ACURÁCIA POR CLASSE	24
3.4 ANÁLISE ESPACIAL DAS CLASSIFICAÇÕES	27
4. DISCUSSÃO	30
5. CONCLUSÃO	32
REFERÊNCIAS BIBLIOGRÁFICAS.....	33

Lista de Ilustrações

Figura 1. Fluxograma metodológico	6
Figura 2. Mapa de localização da área de estudo, correspondendo ao Distrito Federal, destacando os pontos de coleta de amostras utilizados para treinamento e validação da classificação usando aprendizagem profunda em séries temporais.....	7
Figura 3. Imagem lateral de drone evidenciando os padrões de dosséis na Floresta Nacional de Brasília	9
Figura 4. Perfis espectro-temporais médios ($\pm$ desvio-padrão) das 13 classes de uso e cobertura da terra a partir dos mosaicos mensais Planet NICFI (2021–2023)	17
Figura 5. Matrizes de confusão (normalizadas por linha, valores em %) dos melhores modelos por arquitetura: (A) CNN (InceptionTime+), (B) RNN (Bi-LSTM Attention), (C) Transformer (TST+) e (D) Híbrido (Transformer+LSTM)	22
Figura 6. Mapa de uso e cobertura da terra na área de estudo, gerado pela análise espectro-temporal das imagens Planet NICFI (2024) com o método Inception Time. O mapa apresenta as principais classes de uso e cobertura, bem como, as ocorrências das espécies invasoras e oportunistas <i>Tithonia diversifolia</i> e <i>Pteridium arachnoideum</i>	23
Figura 7. Detalhe da detecção da espécie invasora <i>Tithonia diversifolia</i> : (A, C) Imagem Planet (RGB) de maio que demarca a época de floração da espécie, e (B, D) correspondentes imagens com a sobreposição dos polígonos mapeados como a vegetação invasoras (em vermelho)	14
Figura 8. Exemplos de detecção da espécie oportunista <i>Pteridium arachnoideum</i> em áreas de conservação: (A, B) Floresta Nacional de Brasília (Flona de Brasília) e (C, D) Reserva do IBGE. Na parte esquerda, as imagens Planet no espectro do visível (RGB) utilizadas como referência visual; na parte da direita, as respectivas com a sobreposição dos polígonos da invasora (em roxo), ocorrendo predominantemente entremeadas nas áreas de transição de ambientes ripários e fragmentos florestais.....	25

Lista de Tabelas

Tabela 1. Revisão de artigos recentes utilizando séries temporais para detecção de plantas invasoras	3
Tabela 2. Resultados comparativos das métricas de acurácia (acurácia, precisão, recall e F1-score) para os diferentes grupos de modelos avaliados em séries temporais: CNN puros, RNN puros, Transformers puros e modelos híbridos (Transformer + RNN e Transformer + CNN)	19

RESUMO

O principal objetivo desta pesquisa é detectar e mapear a presença de espécies de plantas invasoras e oportunistas (*Tithonia diversifolia* e *Pteridium arachnoideum*) no bioma Cerrado, especialmente em áreas próximas a ambientes urbanos, usando imagens de sensoriamento remoto e técnicas de aprendizado profundo. A rápida disseminação dessas plantas, combinada com seus impactos negativos, representa uma grave ameaça à biodiversidade do Cerrado, um bioma com alta biodiversidade e complexidade ambiental. Os dados utilizados são séries temporais de um ano compostas por imagens mensais Planet fornecidas pelo Norwegian International Climate and Forest Initiative (NICFI), com resolução espacial de 4,77 m e quatro bandas espectrais (azul, verde, vermelho e infravermelho próximo), que apesar do seu potencial vêm sendo subutilizadas no monitoramento de plantas invasoras. O estudo comparou 44 métodos distintos de classificação de séries temporais, incluindo arquiteturas CNNs puras (InceptionTime, FCN, ResNet, TCN, XCM), RNNs puras (LSTM, GRU e suas variantes bidirecionais e com atenção), Transformers puros (TST, TSPerceiver e TSiT) e modelos híbridos (Transformer + RNN e Transformer + CNN). A classificação do cubo espectro-temporal considerou, além das duas plantas invasoras, mais 10 classes distintas de uso e cobertura da terra, possibilitando a redução de erros de confusão com vegetação nativa, agricultura e outros alvos com padrões espectrais e fenológicos semelhantes. Os resultados indicaram que as arquiteturas CNN puras e Transformers puros obtiveram os melhores desempenhos médios, com destaque para o InceptionTime que alcançou 99% de F1-score. Entre os RNNs, as variantes com atenção, como o Bi-LSTM Attention (98,2%), mostraram ganhos relevantes frente às versões tradicionais. No caso dos híbridos, a melhor combinação foi Convolutional Transformer Plus Encoder Learned, atingindo um F1-score de 98,2%.

Palavras-chave: Espécies Invasoras, Bioma Cerrado, Aprendizado Profundo, Sensoriamento Remoto, Estratégias de Conservação

Abstract

The primary objective of this research is to detect and map the presence of invasive and opportunistic plant species (*Tithonia diversifolia* and *Pteridium arachnoideum*), in the Cerrado biome, particularly in areas adjacent to urban

environments, utilizing remote sensing imagery and deep learning techniques. The rapid spread of these plants, combined with their negative impacts, poses a significant threat to the biodiversity of the Cerrado, a biome characterized by high biodiversity and environmental complexity. The data used are one-year time series composed of monthly Planet images provided by the Norwegian International Climate and Forest Initiative (NICFI), with a spatial resolution of 4.77 m and four spectral bands (blue, green, red, and near-infrared), which, despite their potential, have been underutilized in monitoring invasive plants. The study compared 44 different time series classification methods, including pure CNN architectures (InceptionTime, FCN, ResNet, TCN, XCM), pure RNNs (LSTM, GRU, and their bidirectional and attention-based variants), pure Transformers (TST, TSPerceiver, and TSiT), and hybrid models (Transformer + RNN and Transformer + CNN). The spectrotemporal cube classification considered the two invasive plants and 10 distinct land use and land cover classes, aiming to reduce confusion errors with native vegetation, agriculture and other targets that exhibit similar spectral and phenological patterns. The results indicated that pure CNN and pure Transformer architectures achieved the best average performance, highlighting InceptionTime which achieved 99% F1-score. Among the RNNs, attention-based variants, such as Bi-LSTM Attention (98.2%), showed significant improvements over traditional versions. For hybrid, the best combination was Convolutional Transformer Plus Encoder Learned, achieving an F1 score of 98,2%.

Keywords: Invasive Species, Cerrado Biome, Deep Learning, Remote Sensing, Conservation Strategies.

1. INTRODUÇÃO

A disseminação de espécies invasoras é o maior desafio internacional reconhecido pela Convenção sobre Diversidade Biológica (Maney et al., 2024). Intensificada pela conectividade global e pelo crescimento populacional (Pyšek et al., 2020; Xu et al., 2022), as plantas invasoras provocam à homogeneização biótica, à perda de biodiversidade, à alteração dos regimes de incêndio e ao declínio de espécies nativas (Mandle et al., 2011; Sampaio and Schmidt, 2014). Atualmente, existe um alerta dos cientistas sobre a ameaça global das colonizações e disseminações de espécies exóticas invasoras (Pyšek et al., 2020), as quais alteram a estrutura e a composição da comunidade biológica em uma taxa sem precedentes devido ao aumento da conexão mundial e da população (Xu et al., 2022).

No bioma Cerrado, duas espécies se destacam como particularmente problemáticas: a samambaia nativa *Pteridium arachnoideum* (sin. *Pteridium aquilinum* var. *arachnoideum*) e o arbusto exótico *Tithonia diversifolia* (girassol mexicano). *Pteridium arachnoideum* (sin. *P. aquilinum* var. *arachnoideum*) possui status controverso. Enquanto muitos estudos a classificam como invasora devido à sua plasticidade, adaptabilidade e mecanismos de defesa (Taylor e Thomson, 1990; Portela et al., 2009; Guerin e Durigan, 2015), o Instituto Brasileiro do Meio Ambiente e Recursos Minerais (IBRAM) na lista oficial do Distrito Federal não a incluem porque considera apenas espécies exóticas (IBRAM, 2021). Como espécie nativa do Cerrado, é considerada uma pioneira oportunista pós-distúrbio. Essa espécie se propaga por reprodução sexuada e rizomas subterrâneos que conferem resistência a cortes, herbicidas e fogo, enquanto suas densas frondes interceptam a luz solar antes que ela atinja o solo, suprimindo o crescimento de outras plantas.

A *Tithonia diversifolia* (girassol-mexicano) é uma espécie exótica nativa da América Central que atua como planta invasora no bioma Cerrado, caracterizada como um arbusto perene de rápido crescimento, capaz de se propagar por sementes e vegetativamente, competindo com espécies nativas e exercendo efeitos alelopáticos que influenciam sua germinação e crescimento (Ajao and Moteetee, 2017; Muoghalu and Chuba, 2005; Tongma et al., 2001). Amplamente

encontrada em áreas degradadas, beiras de estradas e terrenos baldios (Marrs and Watt, 2006), é oficialmente listada como invasora pelo IBRAM no Distrito Federal. Sua floração amarela brilhante, de maio a agosto, facilita a identificação em campo. No entanto, poucos estudos abordaram o mapeamento espacial dessa vegetação, com destaque para o estudo desenvolvido por Tuyizere et al. (2018), que utilizou sistemas de informação geográfica e técnicas de extrapolação espacial.

A detecção precoce da ocorrência de espécies exóticas invasoras, a monitorização regular do crescimento das populações de espécies exóticas invasoras e a previsão da propagação futura são necessárias para limitar os impactos das espécies exóticas invasoras (Cook et al., 2007). Neste contexto, o emprego de técnicas de sensoriamento remoto tornou-se uma importante ferramenta para o mapeamento e monitoramento de espécies exóticas invasoras. Avanços significativos na aquisição de imagens de sensoriamento remoto a partir de sensores orbitais ou embarcados em drones proporcionaram melhores resoluções espaciais, espectrais e temporais, aumentando a capacidade de detecção de espécies invasoras e, conseqüentemente, de sua aplicação (Huang and Asner, 2009). Devido a importância do tema, diversas revisões da literatura foram realizadas no emprego de sensoriamento remoto para o monitoramento de plantas invasoras (Ahmed et al., 2020; Bradley, 2014; He et al., 2011; Huang and Asner, 2009; Ismail et al., 2016; Niphadkar and Nagendra, 2016; Rocchini et al., 2015; Royimani et al., 2019; Singh et al., 2024; Vaz et al., 2018; Villalobos Perna et al., 2023). Estratégias empregadas por plantas invasoras, como competição, tolerância ao estresse e adaptação mecânica, estão associadas a características específicas que podem ser identificadas por meio do comportamento textural, espectral e temporal das imagens de satélite. Essas características podem advir de alelopatia (Liu et al., 2006), mudanças na estrutura do habitat (Asner et al., 2008), adaptações a perturbações ambientais pelo fogo (Berry et al., 2011; Nunes et al., 2020), alterações por mudanças climáticas (Beaury et al., 2020; Turbelin and Catford, 2021) e modificação da comunidade vegetal (Lazzaro et al., 2020).

Alguns estudos limitam-se ao emprego de uma imagem específica do ciclo fenológico, como a floração (Somodi et al., 2012) ou senescência das folhas

(Ramsey et al., 2002), para a detecção de uma planta invasora. No entanto, a inclusão da dimensão temporal é fundamental para diferenciar um conjunto de variações fenológicas entre as espécies da vegetação nativa e as plantas invasoras ao longo das estações, facilitando seu mapeamento, monitoramento e análise de expansão. Uma análise comparativa entre o emprego de apenas uma cena ou de uma série temporal constituída de seis cenas para mapear Invasive Tamarisk (*Tamarix*) demonstrou uma maior acurácia a partir do conjunto total de imagem (Evangelista et al., 2009).

A **Tabela 1** demonstra uma síntese da variedade de estudos recentes que utilizam séries temporais para a detecção de plantas invasoras. As imagens mais utilizadas são referentes à família Landsat, considerando os diferentes sensores (TM, ETM+, Landsat 8-OLI). A China e os Estados Unidos da América foram os países com mais estudos, considerando diferentes plantas invasoras, com maior quantidade de estudos na detecção de *Spartina alterniflora* em florestas de mangue. O método mais comum entre os estudos são os algoritmos baseados em fenologia (incluindo métricas de bandas e índices fenológicos) e classificador Random Forest (RF).

Os modelos de Deep Learning (DL) atingiram o estado da arte em diversos campos do conhecimento, incluindo a visão computacional e dados sequenciais, tais como texto e áudio. Nos estudos de sensoriamento remoto, diversas revisões demonstram um significativo aumento de desempenho na utilização de métodos de DL para as diversas etapas de processamento de imagens (Ball et al., 2018; L. Ma et al., 2019; Yuan et al., 2020; Zhu et al., 2017). Nos estudos de sensoriamento remoto, as duas principais arquiteturas utilizadas são a CNN e RNN. Recentemente, outra arquitetura que vem se expandindo é o modelo Transformer, especialmente desenvolvido para análise de séries temporais.

As RNNs e o Transformer oferecem uma vantagem distinta no mapeamento de vegetações invasoras ao permitir a exploração de informações temporais e ao lidar bem com amostras pontuais e fragmentadas. Enquanto as CNNs são poderosas para a análise de padrões espaciais contínuos demarcados por anotações de amostras completas em polígonos, os modelos RNNs e Transformer se destacam em cenários em que a dinâmica temporal é crucial e a distribuição de ocorrência não se apresenta como padrões espaciais coesos,

facilitando a seleção de amostras por pontos, como é o caso das plantas invasoras.

Tabela 1. Revisão de artigos recentes utilizando séries temporais para detecção de plantas invasoras.

Artigo	Planta Invasora	Plataforma/Sensor	Método	País
(Diao and Wang, 2016)	Invasive saltcedar in riparian zones (<i>Tamarix spp</i>)	Landsat	Phenology-based algorithm	USA
(César De Sá et al., 2017)	Invasive tree (<i>Acacia longifolia</i>)	Landsat TM/ETM+	Combined rule-based classification and maximum likelihood classification (MLC)	Portugal
(Villarreal et al., 2019)	Invasive annual grasses	Landsat TM and ETM+	Phenology-based algorithm	USA
(Dong et al., 2020)	Invasive plant in mangrove forest (<i>Spartina alterniflora</i>)	Sentinel-1 and 2	Random Forest	China
(Liu et al., 2020)	Invasive plant in mangrove forest (<i>Spartina alterniflora</i>)	Gaofen-1 (GF-1)	Ensemble one-class classifier	China
(Labonté et al., 2020)	Invasive tree in forest (<i>Frangula alnus Mill</i>)	Landsat 8-OLI	Linear temporal unmixing	Canada
(Masemola et al., 2020)	Invasive tree (<i>Acacia</i>)	Sentinel-2	Discriminant Random Forest (DRF)	South Africa
(Singh and Gray, 2020)	Invasive Plants in Urban Forests (<i>Ligustrum sinense</i>)	Landsat	Multiple endmember spectral mixture analysis (MESMA)	USA
(Wu et al., 2020)	Invasive Plant in Mangrove Forest (<i>Spartina alterniflora</i>)	MODIS and Landsat	Phenology-based algorithm	China
(Zhang et al., 2020)	Invasive Plant in Mangrove Forest (<i>Spartina alterniflora</i>)	Landsat	Phenology-based algorithm	China
(Ren et al., 2021)	Invasive plant in mangrove forest (<i>Spartina alterniflora</i>)	Landsat and HJ-1 CCD	SVM and vegetation indices	China
(Xu et al., 2021)	Invasive Plant in Mangrove Forest (<i>Spartina alterniflora</i>)	Sentinel-2A/B	Phenological vegetation index (PVI) threshold-based method	China
(Guo et al., 2022)	Invasive plant in wetland grass (<i>Phragmites australis</i>)	Unmanned Aerial Systems (UAS)	CNN and RNN	USA
(Izadi et al., 2022)	Invasive plant in dry ecosystems (<i>Prosopis juliflora</i>)	Landsat 8-OLI	NDVI difference	Iran
(Zhu et al., 2022)	Invasive Plant in Mangrove Forest (<i>Spartina alterniflora</i>)	Landsat	Deep learning multi-scale residual convolutional neural network (MRCNN) model	China
(Mouta et al., 2023)	Invasive aquatic plant (<i>Eichhornia crassipes</i>)	Sentinel-2	Classifier fusion techniques	Portugal
(Yang et al., 2023)	invasive species in deciduous forests	Sentinel-2	Random Forest	USA
(Hao et al., 2024)	Invasive aquatic plants	Unmanned Aerial Systems (UAS)	CNN	China

Portanto, as Redes Neurais Recorrentes (RNN) mostram-se adequadas na classificação de dados temporais e hiperespectrais, superando os métodos tradicionais de ML (de Castro Filho et al., 2020; A. Ma et al., 2019; Magalhães et al., 2022; Paoletti et al., 2020; Wu and Prasad, 2017). Os métodos de RNN distinguem-se de outras abordagens por incorporar informações de “memória”,

nas quais os dados anteriores influenciam as saídas subsequentes, estabelecendo uma dependência ao longo da sequência ordinal e diferindo das redes neurais profundas tradicionais com entradas e saídas independentes. Entre os métodos de RNN, entre os métodos mais utilizados estão o Long Short-Term Memory (LSTM) (Hochreiter and Schmidhuber, 1997) e Gated Recurrent Units (GRU) (Cho et al., 2014).

Nos estudos de plantas invasoras, a utilização de métodos de DL é ainda incipiente, com destaque para os estudos utilizando CNN em áreas com invasão de plantas em ambientes aquáticos (Hao et al., 2024) e de manguezais (Zhu et al., 2022). Além dessas abordagens, um estudo significativo combina as capacidades do CNN e RNN para o mapeamento de plantas invasoras em manguezais nos Estados Unidos da América (Guo et al., 2022). No entanto, o uso dessas técnicas de DL permanece inexplorado no contexto de plantas invasoras em outros ambientes diferentes de ambientes aquáticos e de manguezais. Portanto, existe um alto potencial de emprego para outros ambientes terrestres de maior complexidade, como o bioma Cerrado, que se diferencia pela rica biodiversidade e alta variação da dinâmica de vegetação, abrindo caminho para futuras pesquisas e aplicações práticas.

O presente estudo foca em plantas invasoras e oportunistas que apresentam uma rápida dispersão na região do Cerrado: samambaia *Pteridium arachnoideum* e o girassol-mexicano *Tithonia diversifolia*. *Pteridium arachnoideum* é uma espécie do gênero *Pteridium*, composto por samambaias herbáceas de distribuição global, adaptáveis a diversos ambientes, exceto desertos, sendo especialmente eficazes em colonizar áreas degradadas e reconhecidas como pioneiras em locais perturbados, apesar de registros desde o Neolítico, sua origem ainda é incerta (Matongera et al., 2018; Page, 1976; Silva Matos and Belinato, 2010; Taylor and Thomson, 1990). A característica marcante do gênero é de possuir uma extensa rede de rizomas e uma alta taxa de crescimento, permitindo capturar a radiação solar antes que ela atinja o solo, criando sombra e dificultando o crescimento de outras espécies, sendo especialmente eficazes em colonizar áreas degradadas e reconhecidas como pioneiras em locais perturbados (Marrs and Watt, 2006). A espécie invasora *Tithonia diversifolia* se espalha agressivamente em ambientes agrícolas e não

agrícolas, tornando-se uma praga significativa e afetando negativamente comunidades vegetais nativas, enquanto seus efeitos alelopáticos influenciam a germinação e o crescimento de diversas outras plantas (Ajao and Moteetee, 2017; Muoghalu and Chuba, 2005; Tongma et al., 2001). Utilizando sistemas de informações geográficas, Tuyizere et al., (2018) mapearam a espécie *Tithonia diversifolia*, empregando técnicas de extrapolação espacial. Até o momento, o gênero *Tithonia diversifolia* não foi estudado utilizando sensoriamento remoto para sua detecção.

A presente pesquisa tem como objetivo principal detectar a presença de plantas invasoras e oportunistas *Tithonia diversifolia* e *Pteridium arachnoideum* no bioma Cerrado, em áreas de reserva, próximas a áreas urbanas e agropecuária, utilizando técnicas de aprendizagem profunda desenvolvidas para séries temporais aplicadas a imagens Planet de composição mensal, disponibilizadas pela Norwegian International Climate and Forest Initiative (NICFI). Este estudo também busca alcançar os seguintes objetivos secundários que introduzem inovações significativas para a detecção desse tipo de alvo:

- Avaliar a detecção de plantas invasoras por sensoriamento remoto em ambientes de alta biodiversidade do Bioma Cerrado, um desafio devido à maior complexidade e ser um ambiente ainda pouco explorado, usando técnicas de séries temporais e métodos de DL.
- Explorar a utilização dos dados da Planet NICFI para a detecção de plantas invasoras, uma abordagem ainda pouco explorada.
- Comparação de modelos de séries temporais organizados em quatro grupos:
 - *CNNs Puros*: Fully Convolutional Network (FCN) (Wang et al., 2017); Residual Network (ResNet) (He et al., 2016), InceptionTime (Ismail Fawaz et al., 2020), Temporal Convolutional Network (TCN) (Bai et al., 2018; Lea et al., 2017), e XCM
 - *RNN puros* (LSTM/GRU e variantes), contendo: Long Short-Term Memory (LSTM) (Hochreiter and Schmidhuber, 1997), Gated Recurrent Unit (GRU) (Cho et al., 2014), Bidirectional Long Short-Term Memory (Bi-LSTM) (Graves and Schmidhuber, 2005), e Bidirectional Gated Recurrent Unit (Bi-GRU) (Luo et al., 2018);

- *Transformers puros*, incluindo: Time Series Transformer (TST) (Foumani et al., 2024), Time Series Perceiver (TSPerceiver) (Jaegle et al., 2021) e Time Series Image Transformer (TSiT) (Dosovitskiy et al., 2021);
- *Híbridos* (junção de métodos), abrangendo: Transformer + GRU (Oguiza, 2023), Transformer + LSTM (Oguiza, 2023), Transformer + RNN (Oguiza, 2023) e Convolutional Transformer Plus (ConvTranPlus) (Foumani et al., 2024);

2. MATERIAIS E MÉTODOS

A abordagem de processamento das imagens consistiu nas seguintes etapas: (a) aquisição da série temporal das imagens Planet NICFI (resolução de 4,77 metros) e confecção dos mosaicos mensais; (b) construção do cubo espaciotemporal, (c) análise do comportamento fenológico da vegetação natural e das plantas invasoras; (d) comparação de métodos de classificação; (e) análise de acurácia; e (f) análise espacial considerando o período 2021-2023 (**Figura 1**).




Figura 1. Fluxograma metodológico.

2.1 Área de Estudo

O Distrito Federal está localizado no centro do Brasil, na região do Planalto Central, e integra a Região Centro-Oeste do país em uma posição estratégica,

próxima ao encontro das bacias hidrográficas Amazônica, Tocantins-Araguaia e São Francisco (**Figura 1**). O Distrito Federal, situado no Planalto Central, possui um clima marcado por duas estações bem definidas: a chuvosa, que vai de outubro a abril, e a seca, de maio a setembro, caracterizada pela baixa umidade relativa do ar. A região apresenta um relevo diversificado, com altitudes que variam entre 850 e 1.340 metros, incluindo áreas planas, suaves ondulações e relevos dissecados ao longo dos principais rios. O Cerrado, bioma predominante na área, é um mosaico de vegetações, dividido em três principais categorias: formações florestais, savânicas e campestres. Dentro dessas categorias, o bioma Cerrado é descrito por onze tipos principais de vegetação (fitofisionomias): as formações florestais incluem mata ciliar, mata de galeria, mata seca e cerradão; as savânicas abrangem o cerrado sentido restrito, parque de cerrado, palmeiral e vereda; enquanto as formações campestres englobam o campo sujo, campo limpo e campo rupestre (Ribeiro and Walter, 2002).




Figura 2. Mapa de localização da área de estudo, correspondendo ao Distrito Federal, destacando os pontos de coleta de amostras utilizados para treinamento e validação da classificação usando aprendizagem profunda em séries temporais.

O Cerrado, reconhecido como a savana mais biodiversa do mundo, abriga 12.385 espécies de plantas nativas catalogadas, das quais cerca de 4 mil são endêmicas. Entretanto, estima-se que 40% de sua vegetação original já foram perdidos, alcançando quase 60% no Distrito Federal. Considerado um dos 25 hotspots globais de biodiversidade, o Cerrado se destaca pela sua extraordinária diversidade biológica, alto grau de endemismo e pela grave ameaça à sua conservação (Myers et al., 2000). Embora compartilhe algumas espécies com biomas adjacentes, a flora do Cerrado é única e notavelmente distinta, refletindo as peculiaridades desse bioma.

2.2 Aquisição de Imagens

A NICFI disponibilizou mosaicos de imagens com resolução de 4,77 m do satélite Planet, cobrindo uma área de 45 milhões de quilômetros quadrados (NICFI, 2024). A constelação de satélites Dove de órbita baixa captura as imagens e fornece revisitas diárias, cobrindo quatro bandas espectrais: azul (455–515 nm), verde (500–590 nm), vermelho (590–670 nm) e infravermelho próximo (780–860 nm) (Planet Team, 2024). Os dados do NICFI de 2015 a 2020 consistem em imagens compostas acumuladas ao longo de 3 a 6 meses. A partir de setembro de 2020, mosaicos com composições mensais individuais tornaram-se disponíveis. A documentação do NICFI descreve o processo de imagem composta que seleciona as melhores imagens sem nuvens e já filtrou parte da cobertura de nuvens dos mosaicos (NICFI, 2024).

O principal objetivo desta iniciativa é entender e combater os efeitos das mudanças climáticas e desenvolver políticas para o uso sustentável e rastreável de serviços ecossistêmicos em regiões tropicais. Esses mosaicos tropicais têm sido usados para melhorar o monitoramento de projetos de restauração de carbono, prever o risco de mortalidade de árvores (Pascual et al., 2022), mapear a degradação florestal (Dalagnol et al., 2023; Wagner et al., 2023; Zhang et al., 2023), plantações agrícolas (Poortinga et al., 2021), ervas marinhas (Lee et al., 2023), entre outras aplicações. O acesso gratuito às imagens tropicais do NICFI está disponível em plataformas como Google Earth Engine, ArcGIS Pro e o Quantum GIS (QGIS) de código aberto. Cada *tile* do Planet NICFI corresponde a 20 × 20 km no solo e tem 4096 × 4096 pixels.

Na área de estudo, que cobre o Distrito Federal, foram selecionados 12 mosaicos da constelação Planet, correspondentes a cada mês do ano de 2021 a 2023. O download das imagens foi realizado no QGIS, utilizando o plugin da Planet, que oferece acesso aos mosaicos mensais para qualquer usuário. Para realizar o mosaico do Distrito Federal, foram utilizados os pontos órbitas “248c, 24dd, 24cb, 24c0, 24cf”. No ArcGIS, os mosaicos foram empilhados para criar o cubo temporal.

2.3 Aquisição de amostras

No presente estudo, a seleção dos pontos contendo as superfícies espectro-temporais considerou os seguintes passos: (a) trabalho de campo identificando e geolocalizando as áreas com presença de *Pteridium arachnoideum* e *Tithonia diversifolia*; (b) seleção de pontos das plantas invasoras e de outros alvos presentes, considerando os padrões identificados no campo e pela interpretação visual de imagens de alta resolução do Google Earth, Planet NICFI e drone; e (c) atividade de campo para confirmar os pontos selecionados.

A seleção de amostras considerou as duas plantas invasoras *Pteridium arachnoideum* e *Tithonia diversifolia* e mais onze alvos: corpos d'água, formação florestal, formação campestre, formação savânica, pastagem, reflorestamento, agricultura, solo exposto, área urbana, sombra e uma classe adicional que engloba as macrófitas e outras vegetações atípicas do Cerrado. A inserção dessas classes adicionais objetivou representar a heterogeneidade da área de estudo e reduzir potenciais confusões espectro-temporais com as invasoras, sobretudo em áreas de transição com a vegetação nativa e usos antrópicos. A realização da seleção de amostras adotou uma forma bem distribuída, sistemática e estratificada (Estabrooks et al., 2004; Foody, 2002). A quantidade de amostras coletadas para cada classe foi de 1.250 amostras, totalizando 16.250 amostras, das quais 60% foram destinadas ao treinamento e 40% à validação.

A **Figura 3** representa uma imagem lateral de drone na Floresta Nacional de Brasília, em que as áreas com presença de *Pteridium arachnoideum* destacam-se por apresentar uma vegetação fotossinteticamente ativa, caracterizada por

um verde mais claro e uma textura veludosa que se difere das demais vegetações.




Figura 3. Imagem lateral de drone evidenciando os padrões de dosséis na Floresta Nacional de Brasília: (A) *Pteridium arachnoideum*; (B) Mata de Galeria; (C) Campestre; e (D) Reflorestamento.

2.4 Algoritmos de Classificação

Os modelos baseados em RNN e Transformer têm mostrado desempenho superior aos métodos tradicionais de Machine Learning para séries temporais, tais como Random Forest (RF) (Breiman, 2001) e Support Vector Machine (SVM) (Vapnik, 1995), possuindo um grande potencial para a classificação de imagens multitemporais. No presente estudo, os modelos avaliados podem ser organizados em quatro grupos principais: (a) Redes Convolutivas (CNNs puros), (b) Redes Neurais Recorrentes (RNNs puros e variantes), (c) Transformers puros e (d) Modelos híbridos (junção Transformer + RNN), abordando os métodos de aprendizagem profunda predominantes na literatura para análise de dados temporais multivariados.

Os métodos baseados em redes convolutivas (CNNs) consolidam-se na análise de séries temporais a partir de convoluções unidimensionais, capazes de extrair padrões locais em diferentes escalas temporais. As variantes das CNNs oferecem soluções complementares que buscam aprimorar o algoritmo conforme as características da série temporal analisada.

O Fully Convolutional Network (FCN) (Wang et al., 2017) foi uma das primeiras arquiteturas baseadas em convoluções utilizadas na classificação de séries temporais. O modelo utiliza camadas convolutivas unidimensionais seguidas de “global average pooling”, eliminando a necessidade de camadas densas totalmente conectadas, reduzindo o número de parâmetros do modelo e o risco de sobreajuste e aumentando a capacidade de generalização.

O Residual Network (ResNet) (He et al., 2016), desenvolvido inicialmente para visão computacional, foi adaptado para séries temporais por meio de convoluções unidimensionais, em que sua principal inovação é o uso de conexões residuais, que permitem o fluxo direto de gradientes entre camadas, evitando a degradação em redes profundas. Nas séries temporais, o ResNet utiliza blocos convolutivos residuais para extração de padrões locais em diferentes níveis.

O método InceptionTime (Ismail Fawaz et al., 2020) utiliza o conceito de blocos Inception de visão computacional para séries temporais, utilizando convoluções paralelas com múltiplas larguras de filtro para capturar padrões em diferentes escalas temporais de forma simultânea, permitindo reconhecer padrões de curta e longa duração sem necessidade de redes excessivamente profundas. A arquitetura utiliza ainda um ensemble de cinco redes Inception idênticas para aumentar a estabilidade do treinamento e versatilidade em cenários univariados e multivariados.

O método Temporal Convolutional Network (TCN) (Lea et al., 2017) foi proposto inicialmente para a segmentação e detecção de ações em sequências de vídeo e posteriormente adaptado para diferentes tarefas de séries temporais (Bai et al., 2018). Essa arquitetura é baseada em convoluções causais, assegurando a consistência temporal com a restrição do acesso da saída a informações presentes e passadas, e em convoluções dilatadas, que ampliam o campo receptivo da rede, permitindo capturar dependências de longo alcance sem a necessidade de redes excessivamente profundas. Além disso, o método incorpora conexões residuais para estabilizar o treinamento e evitar a degradação de desempenho em arquiteturas mais profundas.

O Explainable Convolutional Network for Multivariate Time Series Classification (XCM) (Fauvel et al., 2021) combina convoluções ao longo do tempo com convoluções entre variáveis (*cross-channel*), permitindo capturar simultaneamente padrões temporais e relações entre diferentes dimensões da série. O método utiliza mecanismos de atribuição de relevância, tornando possível identificar os instantes temporais e as variáveis com maior influência na classificação, que o diferencia das CNNs tradicionais, que não oferecem essa transparência do processo.

Os métodos CNNs com o sufixo “Plus” seguem uma lógica de extensão das arquiteturas originais, introduzindo mecanismos de regularização e ajustes estruturais para melhorar a estabilidade do treinamento e a capacidade de generalização (Oguiza, 2023). De modo geral, incluem a adição de batch normalization, dropout e camadas densas de projeção, embora as modificações específicas variem conforme a arquitetura: no FCN Plus, o foco recai sobre a regularização; no ResNet Plus, sobre ajustes de normalização e projeção; no InceptionTime Plus, sobre a ampliação e estabilização dos blocos convolutivos em múltiplas escalas; e no XCM Plus, sobre a robustez das convoluções cross-channel. Assim, o sufixo Plus não representa um único pacote de alterações, mas um conjunto de aprimoramentos adaptados a cada modelo.

Dentre os métodos RNN, os dois mais difundidos são o LSTM (Hochreiter and Schmidhuber, 1997) e o GRU (Cho et al., 2014). O modelo LSTM captura as dependências de longo prazo em séries temporais, utilizando células de memória e portas que regulam o fluxo de informações, permitindo a modelagem de dados sequenciais. O modelo GRU é uma variante simplificada do LSTM que combina as portas de entrada e esquecimento em uma única porta de atualização. Embora o modelo GRU seja simplificado, demonstra eficácia na captura das dependências temporais e é mais rápido do que LSTM. Os modelos bidirecionais Bi-LSTM (Graves and Schmidhuber, 2005) e Bi-GRU (Luo et al., 2018) processam a sequência de dados em duas direções (frente e atrás), capturando tanto informações passadas quanto futuras, tornando o procedimento mais adequado em condições de dependências temporais bidirecionais. Além dessas quatro arquiteturas mais difundidas, foram avaliadas duas variantes para cada uma delas (Plus e Attention) propostas recentemente

por Ignacio Oguiza (2023) na biblioteca tsai. Os modelos com a extensão Attention (LSTM, GRU, Bi-LSTM e Bi-GRU) introduzem um mecanismo de atenção (Bahdanau et al., 2015; Luong et al., 2015), visando superar a limitação do LSTM e GRU clássicos de condensar toda a sequência em um único estado oculto final. Portanto, cada vetor oculto gerado ao longo da sequência recebe um peso de relevância aprendido automaticamente, construindo um vetor de combinação ponderada de todos os instantes temporais que amplia a capacidade de capturar dependências de longo alcance e padrões esparsos. Essa abordagem torna o resultado altamente interpretável, devido aos pesos de atenção indicarem claramente os momentos da série temporal que mais contribuem para a predição final. No caso dos modelos Plus, a arquitetura é mantida como núcleo, mas incorpora camadas adicionais de regularização e estabilização (*batch normalization*, *dropout* e camadas densas de projeção) para reduzir o risco de sobreajuste. Embora a concepção seja a mesma, as implementações variam de acordo com as particularidades de cada célula recorrente, considerando o LSTM com múltiplas portas de entrada, esquecimento e saída, e o GRU, com estrutura mais simplificada baseada em portas de atualização e redefinição.

Os métodos para séries temporais baseados em Transformers puros representam uma evolução às arquiteturas recorrentes e convolutivas tradicionais, ao explorarem o mecanismo de autoatenção para capturar dependências de longo alcance de forma paralela e escalável. O TST (Foumani et al., 2024) é uma adaptação ao domínio temporal do modelo original (Vaswani et al., 2017), introduzindo camadas de *embedding* específicas para séries multivariadas e *positional encoding* para preservar a ordem temporal. O TSPerceiver, inspirado no *Perceiver IO* (Jaegle et al., 2021), objetiva superar o custo quadrático da autoatenção ao utilizar um mecanismo de atenção assimétrica que projeta a entrada para um espaço latente de dimensão reduzida, tornando-o mais adequado para séries longas. O TSiT, baseado no *Vision Transformer* (Dosovitskiy et al., 2021), trata as séries temporais como imagens unidimensionais, aplicando segmentação em patches e atenção global para capturar padrões locais e globais, analogamente ao processamento visual,

permitindo maior paralelismo e melhor generalização em conjuntos de dados extensos.

Os métodos híbridos buscam integrar as vantagens complementares dos diferentes modelos testados, podendo ser subdivididos em duas categorias: combinações de Transformers com RNNs e combinações de Transformers com CNNs. No primeiro grupo, os métodos integram a autoatenção, responsável por capturar dependências de longo alcance de maneira paralela e global, com unidades recorrentes que preservam a modelagem sequencial explícita. A pesquisa testou seis variantes da biblioteca tsai (Oguiza, 2023): Transformer + GRU Plus, Transformer + Bi-GRU Plus, Transformer + LSTM Plus, Transformer + Bi-LSTM Plus, Transformer + RNN Plus e Transformer + Bi-RNN Plus.

No segundo grupo, foram avaliados o modelo híbrido ConvTranPlus (Foumani et al., 2024) e suas variantes, que aliam a eficiência das convoluções na extração de padrões de curto prazo à capacidade dos Transformers em modelar dependências temporais de longo alcance. As camadas convolutivas iniciais, combinadas com blocos Transformer, extraem representações locais e reduzem a carga computacional antes da aplicação da autoatenção. Essa integração possui um caráter complementar entre convoluções e atenção, unindo a capacidade de capturar estruturas locais e globais em séries temporais. A pesquisa avaliou três variações do modelo: ConvTranPlus Default, ConvTranPlus Dim Ff 512 e ConvTranPlus Encoder Learned. A variante ConvTranPlus Dim Ff 512 modifica a dimensão da camada *feed-forward* dos blocos Transformer para 512 unidades, ampliando a capacidade de representação do modelo, o que pode ser vantajoso em bases de dados com alta dimensionalidade. O ConvTranPlus Encoder Learned diferencia-se por empregar um mecanismo de *learned positional encoding* no encoder, em substituição ao *positional encoding* fixo senoidal convencional, facilitando a aprendizagem diretamente da representação posicional mais adequada para os dados temporais, capturando dependências sequenciais específicas do conjunto de treino.

2.5 Avaliação de Precisão

A análise de acurácia avalia a eficácia dos modelos de ML e RNN na classificação das plantas invasoras e das classificações considerando as 13 classes, permitindo a comparação entre os métodos. Neste propósito, as métricas de Overall Accuracy, Precision, Recall e F-Score são amplamente utilizadas, possuindo características complementares. Essas métricas baseadas na matriz de confusão geram quatro possibilidades: verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN). A métrica Overall Accuracy representa a proporção de todas as previsões corretas (VP e VN) em relação ao total de previsões realizadas:

$$\text{Overall Accuracy} = \frac{TP+TN}{TP+TN+FP+F} \quad (1)$$

A métrica Precision mede a proporção de VP em relação ao total de previsões positivas feitas pelo modelo, descrita pela seguinte formulação:

$$\text{Precision} = \frac{TP}{TP+F} \quad (2)$$

O Recall, denominado também como Sensibilidade, mede a proporção de VP em relação ao total de VP existentes no conjunto de dados.

$$\text{Recall} = \frac{TP}{TP+F} \quad (3)$$

O F-Score consiste na média harmônica entre a Precision e o Recall, proporcionando uma única métrica que equilibra os dois aspectos.

$$F - score = \frac{2x(\text{Precision}x\text{Recall})}{\text{Precision}+\text{Recall}} \quad (4)$$

3. RESULTADOS

3.1 Comportamento espectro temporal dos alvos

A análise espectro-temporal das 13 classes de uso e cobertura evidenciou padrões fenológicos distintos (**Figura 4**). As áreas de formação florestal apresentaram valores elevados e estáveis no infravermelho médio (Near-Infrared – NIR) ao longo de todo o ano, acompanhados de baixas reflectâncias nas bandas do visíveis, o que reflete a densidade do dossel e a permanência da biomassa foliar ao longo de todo o período. Apesar de um comportamento estável, observa-se uma sazonalidade discreta, com leve redução do NIR durante a estação seca (junho–agosto) e recuperação nos meses seguintes, no

início do período chuvoso (setembro–outubro). A banda do vermelho (R) manteve a reflectância baixa, mas com pequeno aumento na seca, refletindo a diminuição da densidade foliar e à redução da absorção de clorofila. A baixa variação do desvio-padrão indica que essa classe é relativamente homogênea em relação às demais, contendo menor variabilidade.

A vegetação savânica apresentou valores de NIR relativamente elevados, porém inferiores aos observados nas formações florestais, além de uma variação sazonal mais demarcada. Durante a estação chuvosa, o NIR teve um significativo aumento, refletindo a presença de uma vegetação fotossinteticamente ativa; enquanto na estação seca (junho–agosto) ocorre uma queda expressiva do NIR, associada à perda foliar parcial, senescência e redução da atividade fotossintética. As bandas do visível vermelho, verde e azul (R, G e B) acompanharam esse comportamento de forma inversa: apresentaram valores mais altos na seca, indicando menor absorção da radiação pela clorofila, e redução nos meses úmidos, quando a vegetação está mais verde e densa. O desvio-padrão observado nos boxplots foi mais amplo do que nas florestas, resultante de uma maior heterogeneidade do dossel dentro da classe, coerente com a diversidade fisionômica das savanas. O comportamento fenológico da savana pode eventualmente apresentar confusões com a formação florestal nos meses úmidos e com a classe campestre nos meses secos.

As formações campestres caracterizaram-se com um comportamento sazonal espectro-temporal mais marcado em comparação com as demais classes de vegetação. A banda NIR apresentou valores moderados a baixos, mas com grande amplitude ao longo do ano, apresentando elevação acentuada durante a estação chuvosa, quando há brotação e aumento da biomassa herbácea, e queda pronunciada na estação seca (junho–agosto), refletindo a senescência da vegetação e a redução quase completa da cobertura foliar. As bandas visíveis (R, G e B) também variaram em sincronia com o ciclo fenológico, evidenciando um comportamento espectral de vegetação não fotossinteticamente ativa e com maior exposição do solo no período seco, que contrasta com a vegetação verde e densa durante o período chuvoso. O desvio-padrão elevado em determinados meses indica alta variabilidade espacial, típica de áreas campestres sujeitas a diferentes níveis de degradação e cobertura. A diferenciação do comportamento

fenológico contribui para a separabilidade dessas áreas em relação às demais vegetações naturais, mas aumenta a possibilidade de confusões com a classe pastagem, sobretudo em situações de vegetação degradada ou de cobertura rala durante a seca.

As áreas de reflorestamento apresentaram comportamento espectro-temporal semelhante ao das formações florestais, com valores elevados de NIR durante todo o ano. Observa-se que o NIR se mantém alto na estação chuvosa, refletindo o vigor da vegetação plantada, mas tende a apresentar oscilações mais acentuadas do que nas florestas maduras. Nas bandas do visível (R, G e B), os valores permaneceram baixos, indicando dossel fechado, porém com maiores variações. O desvio-padrão relativamente mais amplo evidenciou uma heterogeneidade, proveniente da inclusão de parcelas jovens e maduras. Em termos de separabilidade, a classe tende a se aproximar da floresta, mas a maior variação temporal e estrutural pode facilitar sua distinção na série temporal completa.

A classe de agricultura caracterizou-se por um comportamento espectro-temporal mais dinâmico e variável em comparação a todas as classes analisadas. O comportamento reflete diretamente os ciclos de plantio, desenvolvimento e colheita característicos da agricultura. Durante o período de estabelecimento das culturas, observam-se valores baixos no NIR e altos nas bandas do visível (R, G e B), resultado da maior exposição do solo. O desenvolvimento da cultura promove o crescimento acentuado do NIR, atingindo valores elevados durante o pico vegetativo, enquanto as bandas do visível diminuem em resposta ao aumento da absorção da clorofila. Após a colheita, ocorre um declínio abrupto do NIR, acompanhado de aumento nas bandas do visível, voltando a um padrão próximo ao do solo exposto. A diversidade de culturas cultivadas (soja, milho, algodão, entre outras) e práticas de manejo resulta em uma acentuada variação fenológica, evidenciada pelo alto desvio-padrão em quase todos os meses. A variabilidade, apesar de aumentar a heterogeneidade da assinatura espectro-temporal, fornece um comportamento distinto, que facilita a separação da agricultura em relação a formações naturais e espécies invasoras.

A classe de solo exposto apresentou um perfil espectro-temporal caracterizado por baixa resposta no NIR e valores relativamente mais altos das bandas do visível (R, G e B), sem variações sazonais significativas. Essas características também resultam em um baixo valor de desvio-padrão. Portanto, a ausência de picos no NIR e a estabilidade das bandas visíveis constituem um contraste marcante em relação às demais classes analisadas.

Semelhante ao solo exposto, a classe de área urbana apresentou um perfil espectro-temporal com ausência de variações ao longo das séries temporais, com baixos valores de NIR. No entanto, existem diferenças marcantes com relação ao solo exposto, mostrando valores mais baixos e achatados em todas as bandas, refletindo a presença de superfícies artificiais, impermeáveis e heterogêneas, como asfalto, telhados e construções. Essa assinatura espectral mais escura e homogênea diferencia a classe urbana do solo exposto, que tende a ser mais clara e variável, dependendo do tipo de solo e da umidade. Além disso, o desvio-padrão foi geralmente menor, indicando maior uniformidade espectral dentro da classe urbana quando comparada às variações de textura e cor típicas de áreas de solo nu. Em síntese, enquanto ambas as classes carecem de dinâmica temporal associada à vegetação, o solo exposto é caracterizado por maior refletância no visível e variação espacial associada às propriedades edáficas, ao passo que a área urbana mostra refletâncias mais baixas e achatadas, características de superfícies construídas.

A classe água apresentou um comportamento espectro-temporal com valores muito baixos e estáveis ao longo do tempo em todas as bandas, especialmente no infravermelho próximo (NIR), em que a refletância se manteve próxima de zero devido à forte absorção no NIR e no vermelho. O desvio-padrão foi mínimo, independentemente da sazonalidade climática. Essas características da água facilitam a distinção dessa classe em relação às demais, exceto em áreas fortemente sombreadas, que também apresentam valores espectrais reduzidos.




Figura 4. Perfis espectro-temporais médios ($\pm$ desvio-padrão) das 13 classes de uso e cobertura da terra a partir dos mosaicos mensais Planet NICFI (2021–2023). Cada boxplot representa a distribuição dos valores digitais para as quatro bandas espectrais (R – vermelho, G – verde, B – azul, NIR – infravermelho próximo) ao longo dos 12 meses do ano. As classes avaliadas foram: 1 – Formações Florestais, 2 – Formações Savânicas, 3 – Formações Campestres, 4 – Pastagem, 5 – Reflorestamento, 6 – Agricultura, 7 – Solo exposto, 8 – Área urbana, 9 – Água, 10 – Samambaião (*Pteridium arachnoideum*), 11 – Margaridão (*Tithonia diversifolia*) e 13 – Macrófitas e outras vegetações atípicas do Cerrado.

A classe *Pteridium arachnoideum* apresentou um comportamento espectro-temporal com valores elevados de NIR, mas com forte variação sazonal entre a estação chuvosa, quando o NIR alcança os valores mais altos devido ao rápido crescimento, e a estação seca (junho–agosto), quando ocorre uma queda acentuada do NIR devido à redução da atividade fotossintética e senescência parcial. O comportamento do *Pteridium arachnoideum* sobrepõe-se à classe de formação florestal em alguns meses úmidos, o que pode provocar uma confusão entre essas classes. O desvio-padrão também é mais amplo do que em outras formações vegetais, refletindo a heterogeneidade proveniente dos mosaicos de densidade variável, geralmente em áreas de borda, clareiras e ambientes perturbados. Portanto, o caráter sazonal e ecologicamente oportunista do *Pteridium arachnoideum* diferencia-o de vegetações mais perenes, mas torna desafiador em cenários de transição.

O margaridão (*Tithonia diversifolia*) durante o período de floração, entre abril e junho, podendo se estender até agosto, apresenta uma dominância visual da cor amarela no campo devido à presença abundante de inflorescências. O comportamento da floração é detectado nos dados espectrais, que apresentam uma redução progressiva do NIR, indicador da diminuição do vigor foliar e da densidade de folhas verdes, concomitante com um leve aumento relativo nas bandas do vermelho e do verde, que resulta na reflectância típica das flores amarelas. O comportamento da floração confere a *Tithonia diversifolia* uma assinatura fenológica característica e de fácil identificação.

A classe de macrófitas com outras vegetações atípicas do Cerrado apresentou um comportamento espectro-temporal com valores elevados de NIR ao longo de todo o ano, típico de vegetação de ambientes aquáticos com alta atividade fotossintética. Nos meses secos, observa-se uma discreta variação sazonal, com ligeira redução do NIR, proveniente da diminuição do nível da lâmina d'água e estresse hídrico. O desvio-padrão é amplo devido à dinâmica sazonal e às diferenças espaciais na densidade de cobertura, que gera uma mistura espectral com a água.

A classe sombra (classe 12) não corresponde a uma classe de cobertura real, mas funciona como categoria auxiliar para reduzir erros de classificação. O comportamento espectro-temporal possui valores muito baixos e achatados em

todas as bandas espectrais, refletindo também em um desvio-padrão baixo. Devido ao seu espectro achatado e ausência de sazonalidade, a sombra pode ser confundida com a água, mas se diferencia por apresentar valores ligeiramente mais elevados nas bandas do NIR, em que a água apresenta valores praticamente nulos.

3.2 Desempenho comparativo dos modelos de aprendizagem profunda

A **Tabela 2** lista os resultados de acurácia da classificação das imagens utilizando os diferentes métodos de aprendizagem profunda em séries temporais. Em todos os modelos, as métricas de acurácia (acurácia, precisão, recall e F1-score) apresentaram valores iguais ou muito próximos devido ao emprego de um conjunto de dados bem balanceado, que evita vieses de classificação e torna as métricas mais harmônicas.

No grupo dos modelos CNN puros, todos os métodos apresentaram alto desempenho, com valores variando de 97,0% a 99,0% e média em torno de 98,3%. A arquitetura InceptionTime atingiu 99,0% para todas as métricas, configurando-se como o melhor resultado dentro do grupo. Atingindo resultados bem próximos, aparecem os modelos ResNet (98,7%), InceptionTime Plus (98,6%) e FCN (98,5%), além de suas variantes ResNet Plus (98,4%) e FCN Plus (98,4%). As arquiteturas XCM (97,4%) e XCM Plus (97,8%) apresentaram resultados ligeiramente inferiores, enquanto o TCN (97,0%) obteve o menor valor dentro do grupo. Portanto, os modelos CNNs mostraram altos valores de métricas independentemente do modelo utilizado.

Os modelos RNN puros apresentaram uma maior variação das métricas em comparação com o grupo das CNNs, oscilando entre 93,4% e 98,5%, com média próxima de 95,9%. Os modelos básicos de LSTM (94,1%) e GRU (93,5%) situaram-se na faixa intermediária, com desempenhos semelhantes às suas variantes bidirecionais, Bi-LSTM (93,6%) e Bi-GRU (94,4%). O melhor resultado foi obtido pelo modelo Bi-LSTM Attention (98,5%), seguido pelas arquiteturas com mecanismos de atenção GRU Attention (97,8%) e Bi-GRU Attention (97,8%). Em contraste, algumas variantes Plus apresentaram desempenho inferior, como o Bi-GRU Plus (93,4%) e o Bi-LSTM Plus (93,7%), que obtiveram os menores valores dentro do grupo.

Tabela 2. Resultados comparativos das métricas de acurácia (acurácia, precisão, recall e F1-score) para os diferentes grupos de modelos avaliados em séries temporais: CNN puros, RNN puros, Transformers puros e modelos híbridos (Transformer + RNN e Transformer + CNN).

Model	Accuracy	Precision	Recall	F1-Score
CNN Puros				
Inception Time	99.0	99.0	99.0	99.0
Inception Time Plus	98.6	98.6	98.6	98.6
FCN	98.5	98.5	98.5	98.5
FCN Plus	98.4	98.4	98.4	98.4
ResNet	98.7	98.7	98.7	98.7
ResNet Plus	98.4	98.4	98.4	98.4
TCN	97	97	97	97
XCM	97.4	97.5	97.4	97.4
XCM Plus	97.8	97.8	97.8	97.8
RNN Puros				
LSTM	94.1	94.1	94.1	94.1
Bi-LSTM	93.6	93.6	93.6	93.6
LSTM Attention	97.5	97.5	97.5	97.5
Bi-LSTM Attention	98.5	98.5	98.5	98.5
LSTM Plus	94.8	94.8	94.8	94.8
Bi-LSTM Plus	93.7	93.7	93.7	93.7
GRU	93.5	93.5	93.5	93.5
Bi-GRU	94.4	94.4	94.4	94.4
Gru Attention	97.8	97.9	97.8	97.8
Bi-GRU Attention	97.8	97.8	97.8	97.8
Gru Plus	93.7	93.7	93.7	93.7
Bi-Gru Plus	93.4	93.5	93.4	93.5
Transformers Puros				
TST Default	98.6	98.6	98.6	98.6
TST H12	98.1	98.1	98.1	98.1
TST H8	98.1	98.1	98.1	98.1
TST Drop05	82.3	85.8	82.3	82.4
TST Plus	98.6	98.6	98.6	98.6
TST Plus H12	98.6	98.7	98.6	98.6
TST Plus H8	98.8	98.8	98.8	98.8
TST Plus Drop05	80	83.7	80	80
Ts Perceiver	90.2	90.3	90.2	90.1
Ts Perceiver 8 Heads	89	89.4	89	88.9
Tsit Plus	93.9	94	93.9	93.9
Tsit Plus H12	93.9	93.9	93.9	93.9
Tsit Plus H8	93	93.1	93	92.9
Tsit Plus Drop05	83.2	84.6	83.2	83.1
Hybrids (Transformer + RNN)				
Transformer + GRU Plus	95.4	95.4	95.4	95.4
Transformer + Bi-GRU Plus	95.7	95.7	95.7	95.7
Transformer + LSTM Plus	95	95.1	95	95
Transformer + Bi-LSTM Plus	95.8	95.8	95.8	95.8
Transformer + RNN Plus	94.6	94.6	94.6	94.6
Transformer + Bi-RNN Plus	91.8	92.1	91.8	91.8
Hybrids (Transformer + CNN)				
Conv Tran Plus	97.9	97.9	97.9	97.9
Conv Tran Plus Dim Ff 512	97.7	97.7	97.7	97.7
Conv Tran Plus Encoder Learned	98.2	98.2	98.2	98.2

No grupo dos Transformers puros, observou-se a maior amplitude de variação entre os resultados, com métricas variando de 80,0% a 98,8% e média em torno de 94,0%. As arquiteturas da família TST apresentaram o melhor desempenho geral, com destaque para o TST Plus H8 (98,8%), seguido pelas variantes TST (98,6%), TST Plus (98,6%) e TST Plus H12 (98,6%). Em contrapartida, algumas variantes com dropout apresentaram acentuada perda de desempenho, tais como o TST Drop05 (82,3%) e o TST Plus Drop05 (80,0%), obtendo os piores resultados do grupo. As arquiteturas TS Perceiver (89,0%–90,2%) e TSiT Plus (93,0%–93,9%) obtiveram resultados intermediários, abaixo do patamar alcançado pelas variantes TST.

Os modelos híbridos que combinam Transformers e RNNs apresentaram resultados que variam entre 91,8% e 95,8% e média em torno de 94,7%. O melhor desempenho foi obtido pelo modelo Transformer + Bi-LSTM Plus (95,8%). As arquiteturas Transformer + Bi-GRU Plus (95,7%) e Transformer + GRU Plus (95,4%), Transformer + LSTM Plus (95,0%) e Transformer + RNN Plus (94,6%) apresentam valores próximos, enquanto o modelo Transformer + Bi-RNN Plus (91,8%) foi o pior resultado dentro do grupo. Comparativamente aos demais grupos, o melhor resultado híbrido supera os RNNs tradicionais (LSTM, GRU, Bi-LSTM e Bi-GRU) e suas versões Plus, perdendo apenas para as arquiteturas RNN com atenção (Bi-LSTM Attention, GRU Attention e Bi-GRU Attention) e aproximando-se dos patamares observados em CNNs e Transformers puros.

Por fim, o grupo dos modelos híbridos Transformer + CNN, composto pelo método ConvTran Plus e suas duas variantes, apresentou resultados entre 97,7% e 98,2% e média de 97,9%. O ConvTran Plus Encoder Learned destacou-se levemente como a melhor configuração, atingindo 98,2%, enquanto as versões padrão e Dim Ff 512 permaneceram praticamente no mesmo patamar (97%).

3.3 Matrizes de confusão e acurácia por classe

Os quatro melhores métodos avaliados em cada grupo apresentaram desempenho elevado, com acurácias globais superiores a 96% e matrizes de confusão com alta concentração na diagonal principal, evidenciando um

predomínio de classificações corretas em todas as classes (**Figura 5**). Os erros associados estão correlacionados com classes de transições ecológicas ou estados intermediários de cobertura, tais como ambientes entre áreas florestais e savânicas ou entre pastagem e solo exposto. Em menor proporção, salienta-se a confusão entre *Pteridium arachnoideum* e as vegetações florestais, provavelmente associada à ocupação desse gênero em bordas e clareiras, resultando em padrões fenológicos semelhantes aos de vegetação arbórea. As classes de água, área urbana, reflorestamento e macrófitas demonstraram uma alta separabilidade espectro-temporal, mantendo baixa taxa de confusão em todos os algoritmos de aprendizado profundo testados. Além disso, a classe da *Tithonia diversifolia* alcançou alta performance, obtendo praticamente 100% de acertos em todos os modelos, apresentando raramente falsos positivos provenientes da classe agricultura. O ciclo fenológico peculiar dessa invasora, marcado por intenso vigor vegetativo e floração, confere uma assinatura temporal bastante distinta, capturada pelos algoritmos.

Nas arquiteturas, os modelos CNN (InceptionTime+) e Transformer (TST+) apresentaram menor número de confusões, restringindo os erros a poucos casos de transição, como a confusão pontual entre florestal e savânica ou entre pastagem e solo exposto. O RNN (Bi-LSTM Attention) evidenciou erros entre classes de vegetação, tais como vegetação florestal e savânica, e entre pastagem e solo exposto, refletindo a dificuldade em capturar padrões mais sutis de variação fenológica. O ConvTran Plus (Encoder Learned) apresentou maior distribuição de erros, incluindo confusões, mesmo em baixa intensidade, entre a formação florestal e *Pteridium arachnoideum*, como também entre agricultura e *Tithonia diversifolia*. Assim, embora todos os métodos tenham mantido elevada acurácia, as diferenças entre arquiteturas ficam mais evidentes na forma como lidam com zonas de transição e classes espectro-temporal próximas.

Especificamente para o melhor modelo InceptionTime, a classe do *Pteridium arachnoideum* (classe 10) apresentou valores elevados de acurácia (Precisão = 1,000; Recall = 0,996; F1 = 0,998). Os erros presentes centralizaram-se exclusivamente na classe florestal, com apenas 1 amostra verdadeira de *Pteridium arachnoideum* rotulada erroneamente como florestal. Esses erros

ocorrem em áreas de transição, nas quais as curvas espectro-fenológicas apresentam comportamento de pixels de mistura.




Figura 5. Matrizes de confusão (normalizadas por linha, valores em %) dos melhores modelos por arquitetura: (A) CNN (InceptionTime+), (B) RNN (Bi-LSTM Attention), (C) Transformer (TST+) e (D) Híbrido (Transformer+LSTM). O eixo y representa as classes verdadeiras e o eixo x as classes preditas, enquanto as variações das cores entre 0 (branco) a 100 (azul) representam a intensidade da classificação correta ou incorreta. As numerações representam as seguintes classes: (1) Florestal, (2) Savânica, (3) Campestre, (4) Pastagem, (5) Reflorestamento, (6) Agricultura, (7) Solo exposto, (8) Área urbana, (9) Água, (10) Samambaião (*Pteridium arachnoideum*), (11) Margaridão (*Tithonia diversifolia*), (12) Sombra e (13) Macrófitas e outras vegetações atípicas do Cerrado.

A *Tithonia diversifolia* (classe 11) obteve um valor de recall perfeito (250/250) sem falsos positivos, indicando separabilidade total frente às demais classes. Os

resultados obtidos para essa classe são de Precisão = 1,000 e F1 = 1,000. Esse comportamento demonstra que a assinatura temporal de *Tithonia diversifolia* é plenamente capturada pelo modelo. Além disso, a classe de macrófitas e outras vegetações atípicas do Cerrado também apresentou desempenho quase perfeito (Precisão = 0,996; Recall = 1,000; F1 = 0,998), com apenas um falso positivo isolado. Os resultados reforçam a discriminação das espécies invasoras pela modelagem.

3.4 Análise espacial das classificações

A **Figura 6** apresenta a classificação espectro-temporal do uso e cobertura da terra por meio do método InceptionTime no Distrito Federal. O mapa delimita claramente as áreas urbanas, reflorestamento e os corpos d'água.




Figura 6. Mapa de uso e cobertura da terra na área de estudo, gerado pela análise espectro-temporal das imagens Planet NICFI (2024) com o método Inception Time. O mapa apresenta as principais classes de uso e cobertura, bem como, as ocorrências das espécies invasoras e oportunistas *Tithonia diversifolia* e *Pteridium arachnoideum*.

As áreas agrícolas concentram-se na porção leste, intercaladas com presença de pastagens e solo exposto, evidenciando a dinâmica de uso agropecuário. As formações florestais concentram-se principalmente nas regiões de áreas

protegidas em torno dos córregos. As áreas destinadas à conservação (por exemplo, Estação Ecológica de Águas Emendadas, Parque Nacional de Brasília e Reserva Ecológica do IBGE) evidenciam as suas extensões cobertas pelas formações de vegetação natural contínua. As formações savânicas apresentam ampla distribuição, estando tanto nas áreas protegidas como em áreas periféricas às manchas agrícolas e urbanas. As espécies invasoras apresentam padrões distintos, no qual o *Pteridium arachnoideum* ocorre de forma mais concentrada em fragmentos florestais e áreas de transição para savanas, evidenciando afinidade com ambientes de borda. Em contraposição, a *Tithonia diversifolia* apresenta distribuição ampla, principalmente associada às margens de rodovias, áreas agrícolas e zonas periurbanas, indicando a alta ocorrência em áreas de perturbação antrópica.

A **Figura 7** apresenta dois exemplos em detalhe da detecção da espécie invasora *Tithonia diversifolia* em zonas periurbanas do Distrito Federal, comparando as imagens Planet NICFI (RGB), adquiridas no mês de maio durante o período de floração, com as respectivas classificações demarcadas por polígonos em vermelho. A ocorrência dessa invasora concentra-se em áreas abertas e margens de solo exposto, frequentemente associadas a zonas de transição entre ambientes urbanos e rurais. As áreas demarcadas pelo modelo apresentam uma forte correspondência espacial com as áreas de tonalidade verde amarelada da imagem Planet, que representam uma feição diagnóstica no comportamento espectro-temporal, proveniente da floração da espécie invasora.

A **Figura 8** ilustra exemplos da detecção da espécie oportunista *Pteridium arachnoideum* em duas áreas de conservação (Floresta Nacional de Brasília e Parque Nacional de Brasília). As áreas classificadas como *Pteridium arachnoideum* concentram-se majoritariamente nas margens dos ambientes ripários e fragmentos florestais, onde as condições de umidade e luminosidade favorecem o seu desenvolvimento. Essa invasora coloniza rapidamente ambientes submetidos a perturbações, principalmente incêndios, como é o caso das áreas apresentadas.




Figura 7. Detalhe da detecção da espécie invasora *Tithonia diversifolia*: (A, C) Imagem Planet NICFI (RGB) de maio que demarca a época de floração da espécie, e (B, D) correspondentes imagens com a sobreposição dos polígonos mapeados de *Tithonia diversifolia* (em vermelho).




Figura 8. Exemplos de detecção da espécie oportunista *Pteridium arachnoideum* em áreas de conservação: (A, B) Floresta Nacional de Brasília (Flona de Brasília) e (C, D) Reserva do IBGE. Na parte esquerda, as imagens Planet NICFI no espectro do visível (RGB) utilizadas como referência visual; na parte da direita, as respectivas com a sobreposição dos polígonos da invasora (em roxo), ocorrendo predominantemente entremeada nas áreas de transição de ambientes ripários e fragmentos florestais.

A Floresta Nacional de Brasília possui um histórico de incêndios com proporções severas, como os ocorridos em 2016, 2017 e 2024, tendo essa última destruído cerca de 2.176 hectares. Neste mesmo contexto, o Parque Nacional de Brasília também apresenta um histórico de grandes incêndios, como os ocorridos em 2010 (aproximadamente 15.600 hectares queimados), 2022 (7.700 hectares) e 2024 (14.000 hectares). Portanto, essa invasora atua como um filtro ecológico e oportunista que dificulta a regeneração de espécies arbóreas, mantendo-se firme mesmo em condições adversas por meio de seu extenso sistema de rizomas. O resultado da classificação, em comparação com as imagens Planet, evidencia a capacidade do modelo em discriminar essa espécie invasora.

4. DISCUSSÃO

Este estudo se diferencia pelos seguintes aspectos: (i) foco no Cerrado e em duas espécies pouco exploradas por sensoriamento remoto, o samambaião (*Pteridium arachnoideum*) e o margaridão (*Tithonia diversifolia*); (ii) realização de uma extensa comparação de métodos considerando 44 modelos de deep learning, abrangendo CNNs, RNNs, Transformers e híbridos; (iii) uso de séries espectro-temporais multiclasse (12 classes), e (iv) ter uma aplicação prática premente para o controle prévio de plantas invasoras.

Embora diversos trabalhos tenham explorado a classificação de séries temporais de imagens de satélite com aprendizagem profunda, uma recente revisão (Cheng et al., 2023) aponta que a maioria das pesquisas está restrita à comparação de um número reduzido de modelos, em que a maior parte das análises existentes se limita entre 3 e 6 arquiteturas, geralmente CNN, LSTM e Random Forest. Nesse contexto, o presente estudo se diferencia por realizar uma extensa comparação de métodos, abrangendo 44 modelos de aprendizagem profunda distribuídos em quatro famílias de arquiteturas (CNNs, RNNs, Transformers e Híbridos).

Além disso, a análise considera um mapeamento com 13 classes de uso e cobertura, em vez de se limitar a um cenário binário simplificado de invasoras versus não-invasoras. Essa estratégia de usar um conjunto amplo de classes permite reduzir significativamente as confusões das espécies invasoras com alvos espectralmente semelhantes, identificando com maior precisão as fontes

de erro e direcionando a uma seleção mais adequada das amostras de treinamento (de Castro Filho et al., 2020), aspecto que ficaria invisível em uma classificação binária. Portanto, as classificações multiclasss oferecem maior capacidade de discriminar nuances ecológicas e urbanas relevantes no monitoramento de invasoras, enquanto modelos binários tendem a mascarar as fontes do problema.

Na separabilidade das classes, a sazonalidade climática do Cerrado exerceu papel determinante na definição dos padrões espectro-temporais. As florestas mantiveram NIR elevado e estável, enquanto savânicas, campestres e pastagens exibiram forte queda no NIR e aumento do visível durante a seca, refletindo perda foliar. Essa dinâmica favoreceu confusões em períodos de transição, como savana com floresta no período úmido e com campo na estiagem. A agricultura mostrou maior variabilidade, com ciclos de plantio e colheita bem definidos. Entre as plantas invasoras e oportunistas, o *Pteridium arachnoideum* apresentou forte sazonalidade e sobreposição com florestas, enquanto a *Tithonia diversifolia* manteve NIR estável e assinatura característica na floração. Os erros residuais provenientes da classe *Pteridium arachnoideum* são devidos aos padrões espectro-temporais semelhantes à vegetação arbórea, sobretudo em ambientes de borda. Em contraste, a *Tithonia diversifolia* apresenta assinaturas espectro-temporais mais bem definidas, mantendo-se com baixas taxas de confusões.

A presente pesquisa possui um caráter de aplicação prática dos modelos de deep learning no monitoramento de espécies invasoras no Cerrado, sendo particularmente importantes para órgãos ambientais e unidades de conservação, que necessitam de um controle precoce da expansão de invasoras. Além disso, os resultados com multiclasss contribuem diretamente para políticas públicas voltadas à conservação e ao uso sustentável da terra, como os planos de manejo do Cerrado e estratégias de preservação da biodiversidade. Assim, o estudo reforça a importância de integrar avanços metodológicos em sensoriamento remoto e aprendizado profundo às práticas de gestão territorial e conservação ambiental.

Como trabalhos futuros, pode-se sugerir pesquisa que inclua bandas espectrais adicionais, como o SWIR, que poderiam contribuir para a discriminação mais

precisa de alvos com assinaturas semelhantes. Além disso, recomenda-se avaliar o impacto da escala temporal no desempenho dos modelos, testando diferentes comprimentos de séries (12, 6 ou 3 meses) para verificar a robustez e a eficiência computacional frente a cenários de monitoramento operacional. Finalmente, uma expansão natural deste trabalho é sua aplicação em outras áreas do Cerrado e em séries multi-ano, o que permitiria acompanhar não apenas a detecção, mas também a dinâmica espacial e temporal da expansão das invasoras, fornecendo subsídios diretos para políticas de conservação e manejo em escala regional.

5. CONCLUSÃO

O presente estudo demonstrou uma alta capacidade do uso de séries temporais Planet NICFI associadas a arquiteturas avançadas de aprendizagem profunda aplicadas a séries temporais para a detecção de espécies invasoras no Cerrado, tema ainda é pouco explorado na literatura. A pesquisa compara um grande número de modelos, totalizando 44 arquiteturas distribuídas em quatro tipos: CNNs puras, Transformers puros, modelos híbridos Transformers + CNN e Transformers + RNN. A classificação adotou uma estratégia de classificação multiclasse, considerando 13 alvos que inclui as duas espécies invasoras. Essa abordagem permite identificar as classes que geram confusão com os alvos pretendidos na pesquisa, permitindo o desenvolvimento de uma seleção mais direcionada do que uma simples classificação binária.

Os resultados apontam que a maioria dos métodos avaliados alcançou uma alta performance, atingindo acurácias globais acima de 95% em praticamente todas as arquiteturas testadas. Entre os grupos de modelos avaliados, as CNNs puras e os Transformers obtiveram os melhores resultados médios, com métricas de acurácia e F1-score próximas a 99%, destacando-se o InceptionTime e o TST Plus H8. Os modelos híbridos Transformer + CNN, como o ConvTran Plus Encoder Learned, também alcançaram resultados elevados, superando 98%. Em contrapartida, os RNNs puros mostraram desempenho inferior em comparação aos demais grupos, com maior variabilidade entre arquiteturas (93%–98%), apesar de que variantes com atenção, como o Bi-LSTM Attention, alcançaram valores aproximados aos melhores resultados. Os modelos híbridos Transformer

+ RNN alcançaram valores intermediários (em torno de 95%), superando os RNNs tradicionais, mas permanecendo abaixo dos CNNs e Transformers puros. O método InceptionTime alcançou os maiores valores de F1-score (99%), evidenciando uma alta capacidade de mapeamento multiclasse, considerando ambientes naturais, agrícolas e urbanos. A *Tithonia diversifolia* apresentou uma assinatura fenológica altamente distinta, caracterizada pelo período de floração, garantindo uma significativa discriminação. O *Pteridium arachnoideum* exibiu comportamento espectro-temporal mais sobreposto às formações florestais, mas ainda assim foi detectado com elevada acurácia, sobretudo em áreas de borda e ambientes ripários, principalmente em áreas de conservação com recorrência de eventos de queimadas. Portanto, as distribuições espaciais demonstraram ser consistentes com as espécies invasoras, em que a *Tithonia diversifolia* aparece em áreas antrópicas e periurbanas, enquanto o *Pteridium arachnoideum* surge em zonas de transição e ambientes submetidos a distúrbios como incêndios. Esses resultados ressaltam a relevância ecológica do método, oferecendo subsídios diretos para gestores ambientais na definição de estratégias de controle e manejo.

O estudo demonstra que a integração entre dados de alta resolução temporal do Planet NICFI e algoritmos de aprendizagem profunda demonstra um avanço significativo no monitoramento de espécies invasoras no Cerrado, com potencial de aplicação em outras regiões e biomas. Pesquisas futuras devem explorar a incorporação de faixas espectrais adicionais (como o infravermelho de ondas curtas - SWIR), séries anuais com intervalos mais curtos, análise plurianual e adaptação dos modelos para rotinas de monitoramento operacional em larga escala, proporcionando uma contribuição para o monitoramento das invasoras visando à conservação da biodiversidade.

REFERÊNCIAS BIBLIOGRÁFICAS

- Ahmed, N., Atzberger, C., Zewdie, W., 2020. Integration of remote sensing and bioclimatic data for prediction of invasive species distribution in data-poor regions: a review on challenges and opportunities. Environ. Syst. Res. 9. <https://doi.org/10.1186/s40068-020-00195-0>
- Ajao, A.A., Moteetee, A.N., 2017. *Tithonia diversifolia* (Hemsl) A. Gray.

- (Asteraceae: Heliantheae), an invasive plant of significant ethnopharmacological importance: A review. *South African J. Bot.* 113, 396–403. <https://doi.org/10.1016/j.sajb.2017.09.017>
- Asner, G.P., Hughes, R.F., Vitousek, P.M., Knapp, D.E., Kennedy-Bowdoin, T., Boardman, J., Martin, R.E., Eastwood, M., Green, R.O., 2008. Invasive plants transform the three-dimensional structure of rain forests. *Proc. Natl. Acad. Sci. U. S. A.* 105, 4519–4523. <https://doi.org/10.1073/pnas.0710811105>
- Bahdanau, D., Cho, K.H., Bengio, Y., 2015. Neural machine translation by jointly learning to align and translate, in: 3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings. San Diego, CA, USA, pp. 1–15.
- Bai, S., Kolter, J.Z., Koltun, V., 2018. An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling.
- Ball, J.E., Anderson, D.T., Chan, C.S., 2018. Special Section Guest Editorial: Feature and Deep Learning in Remote Sensing Applications. *J. Appl. Remote Sens.* 11, 1. <https://doi.org/10.1117/1.jrs.11.042601>
- Beaury, E.M., Fusco, E.J., Jackson, M.R., Laginhas, B.B., Morelli, T.L., Allen, J.M., Pasquarella, V.J., Bradley, B.A., 2020. Incorporating climate change into invasive species management: insights from managers. *Biol. Invasions* 22, 233–252. <https://doi.org/10.1007/s10530-019-02087-6>
- Berry, Z.C., Wevill, K., Curran, T.J., 2011. The invasive weed *Lantana camara* increases fire risk in dry rainforest by altering fuel beds. *Weed Res.* 51, 525–533. <https://doi.org/10.1111/j.1365-3180.2011.00869.x>
- Bradley, B.A., 2014. Remote detection of invasive plants: A review of spectral, textural and phenological approaches. *Biol. Invasions* 16, 1411–1425. <https://doi.org/10.1007/s10530-013-0578-9>
- Breiman, L., 2001. Random Forests. *Mach. Learn.* 45, 5–32. <https://doi.org/10.1023/A:1010933404324>
- César De Sá, N., Carvalho, S., Castro, P., Marchante, E., Marchante, H., 2017. Using Landsat Time Series to Understand How Management and Disturbances Influence the Expansion of an Invasive Tree. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 10, 3243–3253. <https://doi.org/10.1109/JSTARS.2017.2673761>

- Cheng, X., Sun, Y., Zhang, W., Wang, Yihan, Cao, X., Wang, Yanzhao, 2023. Application of Deep Learning in Multitemporal Remote Sensing Image Classification. *Remote Sens.* 15, 3859. <https://doi.org/10.3390/rs15153859>
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., Bengio, Y., 2014. Learning phrase representations using RNN encoder-decoder for statistical machine translation. *EMNLP 2014 - 2014 Conf. Empir. Methods Nat. Lang. Process. Proc. Conf.* 1724–1734. <https://doi.org/10.3115/v1/d14-1179>
- Cook, D.C., Thomas, M.B., Cunningham, S.A., Anderson, D.L., De Barro, P.J., 2007. Predicting the economic impact of an invasive species on an ecosystem service. *Ecol. Appl.* 17, 1832–1840. <https://doi.org/10.1890/06-1632.1>
- Dalagnol, R., Wagner, F.H., Galvão, L.S., Braga, D., Osborn, F., Sagang, L.B., da Conceição Bispo, P., Payne, M., Silva Junior, C., Favrichon, S., Silgueiro, V., Anderson, L.O., Aragão, L.E.O. e. C. de, Fensholt, R., Brandt, M., Ciais, P., Saatchi, S., 2023. Mapping tropical forest degradation with deep learning and Planet NICFI data. *Remote Sens. Environ.* 298. <https://doi.org/10.1016/j.rse.2023.113798>
- de Castro Filho, H.C., Abílio de Carvalho Júnior, O., Ferreira de Carvalho, O.L., Pozzobon de Bem, P., dos Santos de Moura, R., Olino de Albuquerque, A., Rosa Silva, C., Guimarães Ferreira, P.H., Fontes Guimarães, R., Trancoso Gomes, R.A., 2020. Rice Crop Detection Using LSTM, Bi-LSTM, and Machine Learning Models from Sentinel-1 Time Series. *Remote Sens.* 12, 2655. <https://doi.org/10.3390/rs12162655>
- Diao, C., Wang, L., 2016. Incorporating plant phenological trajectory in exotic saltcedar detection with monthly time series of Landsat imagery. *Remote Sens. Environ.* 182, 60–71. <https://doi.org/10.1016/j.rse.2016.04.029>
- Dong, D., Wang, C., Yan, J., He, Q., Zeng, J., Wei, Z., 2020. Combing Sentinel-1 and Sentinel-2 image time series for invasive *Spartina alterniflora* mapping on Google Earth Engine: A case study in Zhangjiang Estuary. *J. Appl. Remote Sens.* 14, 044504. <https://doi.org/10.1117/1.JRS.14.044504>
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., Houlsby, N., 2021. An Image is Worth 16x16 Words: Transformers for Image

- Recognition at Scale. ICLR 2021 - 9th Int. Conf. Learn. Represent.
- Estabrooks, A., Jo, T., Japkowicz, N., 2004. A multiple resampling method for learning from imbalanced data sets. *Comput. Intell.* 20, 18–36. <https://doi.org/10.1111/j.0824-7935.2004.t01-1-00228.x>
- Evangelista, P.H., Stohlgren, T.J., Morisette, J.T., Kumar, S., 2009. Mapping Invasive Tamarisk (*Tamarix*): A Comparison of Single-Scene and Time-Series Analyses of Remotely Sensed Data. *Remote Sens.* 1, 519–533. <https://doi.org/10.3390/rs1030519>
- Fauvel, K., Lin, T., Masson, V., Fromont, É., Termier, A., 2021. XCM: An Explainable Convolutional Neural Network for Multivariate Time Series Classification. *Mathematics* 9, 3137. <https://doi.org/10.3390/math9233137>
- Foody, G.M., 2002. Status of land cover classification accuracy assessment. *Remote Sens. Environ.* 80, 185–201. [https://doi.org/10.1016/S0034-4257\(01\)00295-4](https://doi.org/10.1016/S0034-4257(01)00295-4)
- Foumani, N.M., Tan, C.W., Webb, G.I., Salehi, M., 2024. Improving position encoding of transformers for multivariate time series classification. *Data Min. Knowl. Discov.* 38, 22–48. <https://doi.org/10.1007/s10618-023-00948-2>
- Graves, A., Schmidhuber, J., 2005. Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural Networks* 18, 602–610. <https://doi.org/10.1016/j.neunet.2005.06.042>
- Guo, Y., Zhao, Y., Rothfus, T.A., Avalos, A.S., 2022. A novel invasive plant detection approach using time series images from unmanned aerial systems based on convolutional and recurrent neural networks. *Neural Comput. Appl.* 34, 20135–20147. <https://doi.org/10.1007/s00521-022-07560-3>
- Hao, Z., Lin, L., Post, C.J., Mikhailova, E.A., 2024. Monitoring the spatial–temporal distribution of invasive plant in urban water using deep learning and remote sensing technology. *Ecol. Indic.* 162, 112061. <https://doi.org/10.1016/j.ecolind.2024.112061>
- He, K., Zhang, X., Ren, S., Sun, J., 2016. Deep Residual Learning for Image Recognition, in: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, Las Vegas, NV, USA, pp. 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- He, K.S., Rocchini, D., Neteler, M., Nagendra, H., 2011. Benefits of hyperspectral remote sensing for tracking plant invasions. *Divers. Distrib.* 17, 381–392.

- <https://doi.org/10.1111/j.1472-4642.2011.00761.x>
- Hochreiter, S., Schmidhuber, J., 1997. Long Short-Term Memory. *Neural Comput.* 9, 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Huang, C., Asner, G.P., 2009. Applications of Remote Sensing to Alien Invasive Plant Studies. *Sensors* 9, 4869–4889. <https://doi.org/10.3390/s90604869>
- Ismail Fawaz, H., Lucas, B., Forestier, G., Pelletier, C., Schmidt, D.F., Weber, J., Webb, G.I., Idoumghar, L., Muller, P.-A., Petitjean, F., 2020. InceptionTime: Finding AlexNet for time series classification. *Data Min. Knowl. Discov.* 34, 1936–1962. <https://doi.org/10.1007/s10618-020-00710-y>
- Ismail, R., Mutanga, O., Peerbhay, K., 2016. The identification and remote detection of alien invasive plants in commercial forests: An Overview. *South African J. Geomatics* 5, 49. <https://doi.org/10.4314/sajg.v5i1.4>
- Izadi, F., Chamani, A., Zamani-Ahmadmahooodi, R., 2022. How vegetation cover characteristics response to the spread of *Prosopis juliflora*: a time-series remote sensing analysis in southern Iran. *Environ. Monit. Assess.* 194, 1–12. <https://doi.org/10.1007/s10661-022-09888-8>
- Jaegle, A., Gimeno, F., Brock, A., Zisserman, A., Vinyals, O., Carreira, J., 2021. Perceiver: General Perception with Iterative Attention. *Proc. Mach. Learn. Res.* 139, 4651–4664.
- Labonté, J., Drolet, G., Sylvain, J.D., Thiffault, N., Hébert, F., Girard, F., 2020. Phenology-based mapping of an alien invasive species using time series of multispectral satellite data: A case-study with glossy buckthorn in quebec, Canada. *Remote Sens.* 12. <https://doi.org/10.3390/rs12060922>
- Lazzaro, L., Bolpagni, R., Buffa, G., Gentili, R., Lonati, M., Stinca, A., Acosta, A.T.R., Adorni, M., Aleffi, M., Allegrezza, M., Angiolini, C., Assini, S., Bagella, S., Bonari, G., Bovio, M., Bracco, F., Brundu, G., Caccianiga, M., Carnevali, L., Di Cecco, V., Ceschin, S., Ciaschetti, G., Cogoni, A., Foggi, B., Frattaroli, A.R., Genovesi, P., Gigante, D., Lucchese, F., Mainetti, A., Mariotti, M., Minissale, P., Paura, B., Pellizzari, M., Perrino, E.V., Pirone, G., Poggio, L., Poldini, L., Poponessi, S., Prisco, I., Prosser, F., Puglisi, M., Rosati, L., Selvaggi, A., Sottovia, L., Spampinato, G., Stanisci, A., Venanzoni, R., Viciani, D., Vidali, M., Villani, M., Lastrucci, L., 2020. Impact of invasive alien plants on native plant communities and Natura 2000 habitats: State of the art, gap analysis and perspectives in Italy. *J. Environ. Manage.* 274, 111140.

- <https://doi.org/10.1016/j.jenvman.2020.111140>
- Lea, C., Flynn, M.D., Vidal, R., Reiter, A., Hager, G.D., 2017. Temporal Convolutional Networks for Action Segmentation and Detection, in: 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, pp. 1003–1012. <https://doi.org/10.1109/CVPR.2017.113>
- Lee, C.B., Martin, L., Traganos, D., Antat, S., Baez, S.K., Cupidon, A., Faure, A., Harlay, J., Morgan, M., Mortimer, J.A., Reinartz, P., Rowlands, G., 2023. Mapping the National Seagrass Extent in Seychelles Using PlanetScope NICFI Data. *Remote Sens.* 15. <https://doi.org/10.3390/rs15184500>
- Liu, J., Dong, M., Miao, S.L., Li, Z.Y., Song, M.H., Wang, R.Q., 2006. Invasive alien plants in China: Role of clonality and geographical origin. *Biol. Invasions* 8, 1461–1470. <https://doi.org/10.1007/s10530-005-5838-x>
- Liu, X., Liu, H., Datta, P., Frey, J., Koch, B., 2020. Mapping an invasive plant *Spartina alterniflora* by combining an ensemble one-class classification algorithm with a phenological NDVI time-series analysis approach in middle coast of Jiangsu, China. *Remote Sens.* 12, 1–24. <https://doi.org/10.3390/rs12244010>
- Luo, X., Zhou, W., Wang, W., Zhu, Y., Deng, J., 2018. Attention-Based Relation Extraction With Bidirectional Gated Recurrent Unit and Highway Network in the Analysis of Geological Data. *IEEE Access* 6, 5705–5715. <https://doi.org/10.1109/ACCESS.2017.2785229>
- Luong, M.T., Pham, H., Manning, C.D., 2015. Effective approaches to attention-based neural machine translation, in: Conference Proceedings - EMNLP 2015: Conference on Empirical Methods in Natural Language Processing. Lisbon, Portugal, pp. 1412–1421. <https://doi.org/10.18653/v1/d15-1166>
- Ma, A., Filippi, A.M., Wang, Z., Yin, Z., 2019. Hyperspectral image classification using similarity measurements-based deep recurrent neural networks. *Remote Sens.* 11, 1–19. <https://doi.org/10.3390/rs11020194>
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., Johnson, B.A., 2019. Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS J. Photogramm. Remote Sens.* 152, 166–177. <https://doi.org/10.1016/j.isprsjprs.2019.04.015>
- Magalhães, I.A.L., de Carvalho Júnior, O.A., de Carvalho, O.L.F., de Albuquerque, A.O., Hermuche, P.M., Merino, É.R., Gomes, R.A.T.,

- Guimarães, R.F., Ferreira de Carvalho, O.L., de Albuquerque, A.O., Hermuche, P.M., Merino, É.R., Gomes, R.A.T., Guimarães, R.F., de Carvalho, O.L.F., de Albuquerque, A.O., Hermuche, P.M., Merino, É.R., Gomes, R.A.T., Guimarães, R.F., 2022. Comparing Machine and Deep Learning Methods for the Phenology-Based Classification of Land Cover Types in the Amazon Biome Using Sentinel-1 Time Series. *Remote Sens.* 14, 4858. <https://doi.org/10.3390/rs14194858>
- Mandle, L., Bufford, J.L., Schmidt, I.B., Daehler, C.C., 2011. Woody exotic plant invasions and fire: reciprocal impacts and consequences for native ecosystems. *Biol. Invasions* 13, 1815–1827. <https://doi.org/10.1007/s10530-011-0001-3>
- Maney, C., Guaras, D., Harrison, J., Guizar-Coutiño, A., Harfoot, M.B.J., Hill, S.L.L., Burgess, N.D., Sutherland, W., 2024. National commitments to Aichi Targets and their implications for monitoring the Kunming-Montreal Global Biodiversity Framework. *npj Biodivers.* 3, 1–8. <https://doi.org/10.1038/s44185-024-00039-5>
- Marrs, R.H., Watt, A.S., 2006. Biological flora of the British Isles: *Pteridium aquilinum* (L.) Kuhn. *J. Ecol.* 94, 1272–1321. <https://doi.org/10.1111/j.1365-2745.2006.01177.x>
- Masemola, C., Cho, M.A., Ramoelo, A., 2020. Sentinel-2 time series based optimal features and time window for mapping invasive Australian native Acacia species in KwaZulu Natal, South Africa. *Int. J. Appl. Earth Obs. Geoinf.* 93, 102207. <https://doi.org/10.1016/j.jag.2020.102207>
- Matongera, T.N., Mutanga, O., Dube, T., Lottering, R.T., 2018. Detection and mapping of bracken fern weeds using multispectral remotely sensed data: a review of progress and challenges. *Geocarto Int.* 33, 209–224. <https://doi.org/10.1080/10106049.2016.1240719>
- Mouta, N., Silva, R., Pinto, E.M., Vaz, A.S., Alonso, J.M., Gonçalves, J.F., Honrado, J., Vicente, J.R., 2023. Sentinel-2 Time Series and Classifier Fusion to Map an Aquatic Invasive Plant Species along a River—The Case of Water-Hyacinth. *Remote Sens.* 15. <https://doi.org/10.3390/rs15133248>
- Muoghalu, J.I., Chuba, D.K., 2005. Seed germination and reproductive strategies of *Tithonia diversifolia* (Hemsl.) gray and *Tithonia rotundifolia* (P.M) blake. *Appl. Ecol. Environ. Res.* 3, 39–46.

- https://doi.org/10.15666/aeer/0301_039046
- Myers, N., Mittermeier, R.A., Mittermeier, C.G., da Fonseca, G.A.B., Kent, J., 2000. Biodiversity hotspots for conservation priorities. *Nature* 403, 853–858. <https://doi.org/10.1038/35002501>
- NICFI, 2024. Norway's international climate and forest initiative (NICFI) [WWW Document]. URL <https://www.nicfi.no/> (accessed 6.1.24).
- Niphadkar, M., Nagendra, H., 2016. Remote sensing of invasive plants: incorporating functional traits into the picture. *Int. J. Remote Sens.* 37, 3074–3085. <https://doi.org/10.1080/01431161.2016.1193795>
- Nunes, L.J.R., Raposo, M.A.M., Meireles, C.I.R., Pinto Gomes, C.J., Almeida Ribeiro, N.M.C., 2020. Fire as a selection agent for the dissemination of invasive species: Case study on the evolution of forest coverage. *Environ. - MDPI* 7, 1–14. <https://doi.org/10.3390/environments7080057>
- Oguiza, I., 2023. TSAI - A state-of-the-art deep learning library for time series and sequential data.
- Page, C.N., 1976. The taxonomy and phytogeography of bracken-a review. *Bot. J. Linn. Soc.* 73, 1–34. <https://doi.org/10.1111/j.1095-8339.1976.tb02010.x>
- Paoletti, M.E., Haut, J.M., Plaza, J., Plaza, A., 2020. Scalable recurrent neural network for hyperspectral image classification. *J. Supercomput.* 76, 8866–8882. <https://doi.org/10.1007/s11227-020-03187-0>
- Pascual, A., Tupinambá-Simões, F., Guerra-Hernández, J., Bravo, F., 2022. High-resolution planet satellite imagery and multi-temporal surveys to predict risk of tree mortality in tropical eucalypt forestry. *J. Environ. Manage.* 310, 114804. <https://doi.org/10.1016/j.jenvman.2022.114804>
- Planet Team, 2024. Planet Application Program Interface: In Space for Life on Earth [WWW Document]. URL <https://api.planet.com> (accessed 6.1.24).
- Poortinga, A., Thwal, N.S., Khanal, N., Mayer, T., Bhandari, B., Markert, K., Nicolau, A.P., Dilger, J., Tenneson, K., Clinton, N., Saah, D., 2021. Mapping sugarcane in Thailand using transfer learning, a lightweight convolutional neural network, NICFI high resolution satellite imagery and Google Earth Engine. *ISPRS Open J. Photogramm. Remote Sens.* 1, 100003. <https://doi.org/10.1016/j.ophoto.2021.100003>
- Pyšek, P., Hulme, P.E., Simberloff, D., Bacher, S., Blackburn, T.M., Carlton, J.T., Dawson, W., Essl, F., Foxcroft, L.C., Genovesi, P., Jeschke, J.M., Kühn, I.,

- Liebhold, A.M., Mandrak, N.E., Meyerson, L.A., Pauchard, A., Pergl, J., Roy, H.E., Seebens, H., van Kleunen, M., Vilà, M., Wingfield, M.J., Richardson, D.M., 2020. Scientists' warning on invasive alien species. *Biol. Rev.* 95, 1511–1534. <https://doi.org/10.1111/brv.12627>
- Ramsey, E.W., Nelson, G.A., Sapkota, S.K., Seeger, E.B., Martella, K.D., 2002. Mapping Chinese tallow with color-infrared photography. *Photogramm. Eng. Remote Sensing* 68, 251–255.
- Ren, G., Zhao, Y., Wang, J., Wu, P., Ma, Y., 2021. Ecological effects analysis of *Spartina alterniflora* invasion within Yellow River delta using long time series remote sensing imagery. *Estuar. Coast. Shelf Sci.* 249. <https://doi.org/10.1016/j.ecss.2020.107111>
- Ribeiro, J.F., Walter, B.M.T., 2002. As Principais Fitofisionomias do Bioma Cerrado, in: Sano, S.M., Almeida, S.P. de, Ribeiro, J.F. (Eds.), *Cerrado Ecologia e Flora*. Embrapa Cerrados, Brasília, DF, pp. 151–199.
- Rocchini, D., Andreo, V., Förster, M., Garzon-Lopez, C.X., Gutierrez, A.P., Gillespie, T.W., Hauffe, H.C., He, K.S., Kleinschmit, B., Mairota, P., Marcantonio, M., Metz, M., Nagendra, H., Pareeth, S., Ponti, L., Ricotta, C., Rizzoli, A., Schaab, G., Zebisch, M., Zorer, R., Neteler, M., 2015. Potential of remote sensing to predict species invasions. *Prog. Phys. Geogr. Earth Environ.* 39, 283–309. <https://doi.org/10.1177/0309133315574659>
- Royimani, L., Mutanga, O., Odindi, J., Dube, T., Matongera, T.N., 2019. Advancements in satellite remote sensing for mapping and monitoring of alien invasive plant species (AIPs). *Phys. Chem. Earth* 112, 237–245. <https://doi.org/10.1016/j.pce.2018.12.004>
- Sampaio, A.B., Schmidt, I.B., 2014. Espécies exóticas invasoras em unidades de conservação federais do Brasil. *Biodiversidade Bras.* 32–49.
- Silva Matos, D., Belinato, T., 2010. Interference of *Pteridium arachnoideum* (Kaulf.) Maxon. (Dennstaedtiaceae) on the establishment of rainforest trees. *Brazilian J. Biol.* 70, 311–316. <https://doi.org/10.1590/S1519-69842010000200012>
- Singh, K.K., Gray, J., 2020. Mapping understory invasive plants in urban forests with spectral and temporal Unmixing of Landsat imagery. *Photogramm. Eng. Remote Sensing* 86, 509–518. <https://doi.org/10.14358/PERS.86.8.509>
- Singh, K.K., Surasinghe, T.D., Frazier, A.E., 2024. Systematic review and best

- practices for drone remote sensing of invasive plants. *Methods Ecol. Evol.* 15, 998–1015. <https://doi.org/10.1111/2041-210X.14330>
- Somodi, I., Čarni, A., Ribeiro, D., Podobnikar, T., 2012. Recognition of the invasive species *Robinia pseudacacia* from combined remote sensing and GIS sources. *Biol. Conserv.* 150, 59–67. <https://doi.org/10.1016/j.biocon.2012.02.014>
- Taylor, J.E., Thomson, J.A., 1990. Allelopathic activity of frond run-off from *Pteridium esculentum*, in: *AIAS-Occasional-Publication*. 1990, No. 40, 203–208; 13 Ref., In *Proceedings of the International Conference Bracken 89 Held in Sydney, Australia, 18-21 July 1989*.
- Tongma, S., Kobayashi, K., Usui, K., 2001. Allelopathic activity of Mexican sunflower [*Tithonia diversifolia* (Hemsl.) A. Gray] in soil under natural field conditions and different moisture conditions. *Weed Biol. Manag.* 1, 115–119. <https://doi.org/10.1046/j.1445-6664.2001.00020.x>
- Turbelin, A., Catford, J.A., 2021. Invasive plants and climate change, in: *Climate Change*. Elsevier, pp. 515–539. <https://doi.org/10.1016/B978-0-12-821575-3.00025-6>
- Tuyizere, J., Kayitete, L., Uhawenimana, P.M., Bazizane, F., Uwiragiye, P., Mukashyaka, C., Nshutiyayesu, S., 2018. Mapping of Distribution of Invasive Species in Ruhande Arboretum, in: *2018 EAJST Special*. pp. 15–27.
- Vapnik, V., 1995. *The nature of statistical learning theory*. Springer, New York.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Polosukhin, I., 2017. Attention is all you need, in: Guyon, I., Von Luxburg, U., Bengio, S., Wallach, H., Fergus, R., Vishwanathan, S., Garnett, R. (Eds.), *Advances in Neural Information Processing Systems 30 (NIPS 2017)*. 31st Conference on Neural Information Processing Systems. Long Beach, CA, USA.
- Vaz, A.S., Alcaraz-Segura, D., Campos, J.C., Vicente, J.R., Honrado, J.P., 2018. Managing plant invasions through the lens of remote sensing: A review of progress and the way forward. *Sci. Total Environ.* 642, 1328–1339. <https://doi.org/10.1016/j.scitotenv.2018.06.134>
- Villalobos Perna, P., Di Febbraro, M., Carranza, M.L., Marzioletti, F., Innangi, M., 2023. Remote Sensing and Invasive Plants in Coastal Ecosystems: What We Know So Far and Future Prospects. *Land* 12.

- <https://doi.org/10.3390/land12020341>
- Villarreal, M., Soulard, C., Waller, E., 2019. Landsat Time Series Assessment of Invasive Annual Grasses Following Energy Development. *Remote Sens.* 11, 2553. <https://doi.org/10.3390/rs11212553>
- Wagner, F.H., Dalagnol, R., Silva-Junior, C.H.L., Carter, G., Ritz, A.L., Hirye, M.C.M., Ometto, J.P.H.B., Saatchi, S., 2023. Mapping Tropical Forest Cover and Deforestation with Planet NICFI Satellite Images and Deep Learning in Mato Grosso State (Brazil) from 2015 to 2021. *Remote Sens.* 15. <https://doi.org/10.3390/rs15020521>
- Wu, H., Prasad, S., 2017. Convolutional recurrent neural networks for hyperspectral data classification. *Remote Sens.* 9. <https://doi.org/10.3390/rs9030298>
- Wu, Y., Xiao, X., Chen, B., Ma, J., Wang, X., Zhang, Y., Zhao, B., Li, B., 2020. Tracking the phenology and expansion of *Spartina alterniflora* coastal wetland by time series MODIS and Landsat images. *Multimed. Tools Appl.* 79, 5175–5195. <https://doi.org/10.1007/s11042-018-6314-9>
- Xu, H., Liu, Q., Wang, S., Yang, G., Xue, S., 2022. A global meta-analysis of the impacts of exotic plant species invasion on plant diversity and soil properties. *Sci. Total Environ.* 810, 152286. <https://doi.org/10.1016/j.scitotenv.2021.152286>
- Xu, R., Zhao, S., Ke, Y., 2021. A Simple Phenology-Based Vegetation Index for Mapping Invasive *Spartina Alterniflora* Using Google Earth Engine. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 14, 190–201. <https://doi.org/10.1109/JSTARS.2020.3038648>
- Yang, X., Qiu, S., Zhu, Z., Rittenhouse, C., Riordan, D., Cullerton, M., 2023. Mapping understory plant communities in deciduous forests from Sentinel-2 time series. *Remote Sens. Environ.* 293, 113601. <https://doi.org/10.1016/j.rse.2023.113601>
- Yuan, Q., Shen, H., Li, T., Li, Z., Li, S., Jiang, Y., Xu, H., Tan, W., Yang, Q., Wang, J., Gao, J., Zhang, L., 2020. Deep learning in environmental remote sensing: Achievements and challenges. *Remote Sens. Environ.* 241, 111716. <https://doi.org/10.1016/j.rse.2020.111716>
- Zhang, X., Xiao, X., Wang, X., Xu, X., Chen, B., Wang, J., Ma, J., Zhao, B., Li, B., 2020. Quantifying expansion and removal of *Spartina alterniflora* on

- Chongming island, China, using time series Landsat images during 1995–2018. *Remote Sens. Environ.* 247. <https://doi.org/10.1016/j.rse.2020.111916>
- Zhang, Y., Wang, X., Li, X., Du, Y., Atkinson, P.M., 2023. Monitoring monthly tropical humid forest disturbances with planet NICFI images in Cameroon. *Agric. For. Meteorol.* 341, 109676. <https://doi.org/10.1016/j.agrformet.2023.109676>
- Zhu, W., Ren, G., Wang, Jianping, Wang, Jianbu, Hu, Y., Lin, Z., Li, W., Zhao, Y., Li, S., Wang, N., 2022. Monitoring the Invasive Plant *Spartina alterniflora* in Jiangsu Coastal Wetland Using MRCNN and Long-Time Series Landsat Data. *Remote Sens.* 14. <https://doi.org/10.3390/rs14112630>
- Zhu, X.X., Tuia, D., Mou, L., Xia, G., Zhang, L., Xu, F., Fraundorfer, F., 2017. Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources. *IEEE Geosci. Remote Sens. Mag.* 5, 8–36. <https://doi.org/10.1109/MGRS.2017.2762307>