

Uso de GeoAI e Sensoriamento Remoto Multimodal no Monitoramento da Biodiversidade Amazônica: Uma Revisão Sistemática

The Use of GeoAI and Multimodal Remote Sensing in Monitoring Amazonian Biodiversity: A Systematic Review

¹Esther Rodrigues Alves dos Reis

¹Bacharel em Ciências Biológicas – Universidade Estácio de Sá (estherreis2012@gmail.com)

RESUMO: A Amazônia desempenha papel fundamental na manutenção da biodiversidade global e na regulação climática, porém sofre crescentes pressões relacionadas ao desmatamento, degradação florestal e mudanças no uso da terra. Nesse contexto, o presente estudo teve como objetivo realizar uma revisão sistemática da literatura científica sobre aplicações de GeoAI, sensoriamento remoto multimodal e inteligência artificial no monitoramento da biodiversidade amazônica. A revisão foi conduzida conforme as recomendações do protocolo PRISMA 2020, com buscas realizadas nas bases Scopus, Web of Science, ScienceDirect, PubMed e IEEE Xplore. Após aplicação dos critérios de inclusão e exclusão, 35 estudos foram selecionados para análise. Os resultados evidenciaram predominância de aplicações voltadas ao monitoramento de desmatamento, biomassa, degradação florestal e estrutura da vegetação, utilizando principalmente redes neurais convolucionais, aprendizado profundo e integração entre sensores ópticos, LiDAR, SAR e drones/UAS. Observou-se crescimento expressivo das publicações após 2020, associado à ampliação de abordagens multimodais e plataformas geoespaciais em nuvem. Os estudos demonstraram elevado desempenho analítico na detecção de padrões ambientais complexos, embora persistam limitações relacionadas à heterogeneidade metodológica, disponibilidade de dados rotulados e validação externa dos modelos. Conclui-se que a GeoAI apresenta elevado potencial estratégico para fortalecer o monitoramento ambiental amazônico e subsidiar ações de conservação, manejo florestal e planejamento territorial.

Palavras-chave: Aprendizado Profundo; Conservação Ambiental; Ecossistemas Tropicais; Geotecnologias; Monitoramento Florestal; Sensores Multimodais.

ABSTRACT: The Amazon rainforest plays a fundamental role in maintaining global biodiversity and climate regulation, yet it faces increasing pressures associated with deforestation, forest degradation, and land-use change. In this context, the present study aimed to conduct a systematic review of the scientific literature on applications of GeoAI, multimodal remote sensing, and artificial intelligence for monitoring Amazonian biodiversity. The review followed the PRISMA 2020 guidelines, with searches conducted in the Scopus, Web of Science, ScienceDirect, PubMed, and IEEE Xplore databases. After applying the inclusion and exclusion criteria, 35 studies were selected for analysis. The results revealed a predominance of applications related to deforestation monitoring, biomass estimation, forest degradation, and vegetation structure, mainly using convolutional neural networks, deep learning, and the integration of optical, LiDAR, SAR, and drone/UAS sensors. A significant increase in publications after 2020 was observed, associated with the expansion of multimodal approaches and cloud-based geospatial platforms. The studies demonstrated high analytical performance in detecting complex environmental patterns, although limitations related to methodological heterogeneity, availability of labeled datasets, and external model validation remain important challenges. It is concluded that GeoAI has strong strategic potential to strengthen Amazon environmental monitoring and support conservation, forest management, and territorial planning actions.

Keywords: Deep Learning; Environmental Conservation; Forest Monitoring; Multimodal Sensors; Tropical Ecosystems; Geotechnologies.

Recebido em:
14/05/2026
Revisado em:
18/08/2026
Publicado em:
28/09/2026

1. INTRODUÇÃO

A Amazônia constitui a maior floresta tropical contínua do planeta e abriga uma das mais elevadas concentrações de biodiversidade conhecidas, desempenhando papel estratégico na manutenção dos ciclos hidrológicos, armazenamento de carbono e regulação climática

global (Malhi et al. 2008; Lovejoy 2017; Guayasamin et al. 2024). Entretanto, processos intensivos de desmatamento, degradação florestal, queimadas e mudanças no uso da terra vêm comprometendo a integridade ecológica da região e ampliando sua vulnerabilidade ambiental (Lapola et al. 2023; Mataveli et al. 2025). Nesse contexto, o monitoramento ambiental contínuo tornou-se essencial para subsidiar estratégias de conservação, manejo florestal sustentável e planejamento territorial baseado em evidências científicas.

O monitoramento da biodiversidade amazônica apresenta desafios significativos relacionados à dimensão territorial da floresta, elevada heterogeneidade ambiental e limitações operacionais dos métodos convencionais de levantamento em campo. Técnicas tradicionais frequentemente demandam alto esforço logístico, elevados custos operacionais e extensos períodos de coleta e processamento de dados, dificultando análises contínuas em larga escala espacial e temporal (Turner et al. 2003; Pettorelli et al. 2014). Nesse cenário, o avanço das geotecnologias ampliou significativamente a capacidade de aquisição, processamento e análise de dados ambientais em ecossistemas tropicais.

Nas últimas décadas, o sensoriamento remoto consolidou-se como uma das principais ferramentas aplicadas ao monitoramento ambiental tropical. Dados provenientes de sensores ópticos, radar de abertura sintética (SAR), LiDAR e plataformas aéreas não tripuladas (UAS/drones) vêm sendo empregados em aplicações relacionadas ao monitoramento da cobertura vegetal, biomassa, degradação florestal e mudanças no uso da terra (Asner et al. 2010; Hansen et al. 2013). Paralelamente, técnicas de inteligência artificial (IA) e aprendizado de máquina passaram a ser amplamente incorporadas às análises geoespaciais e ecológicas. Nesse contexto, o termo GeoAI refere-se à integração entre inteligência artificial, ciência geoespacial e análise de dados ambientais, possibilitando a identificação automatizada de padrões espaciais complexos em grandes volumes de dados geográficos (Zhu et al. 2017; Reichstein et al. 2019; Tuia et al. 2024).

Entre as principais abordagens aplicadas destacam-se algoritmos de machine learning, deep learning e redes neurais convolucionais (CNNs), empregados em tarefas de classificação de imagens, segmentação ambiental, modelagem espacial e detecção automatizada de mudanças ecológicas. Aplicações recentes em ecossistemas amazônicos têm demonstrado avanços importantes na detecção de degradação florestal, análise multitemporal de imagens orbitais, modelagem da estrutura da vegetação e monitoramento automatizado da fauna (Norouzzadeh et al. 2018; Ball et al. 2022; Dalagnol et al. 2022; Kim et al. 2022; Dal Molin et al. 2026; Valle et al. 2026).

Apesar do crescimento expressivo dessas aplicações, revisões sistemáticas voltadas especificamente à integração entre GeoAI, sensoriamento remoto multimodal e monitoramento da biodiversidade amazônica ainda permanecem limitadas. Grande parte das revisões existentes concentra-se isoladamente em aplicações de sensoriamento remoto, inteligência artificial ambiental ou monitoramento florestal, sem integrar de forma abrangente sensores multissensoriais, algoritmos avançados de aprendizado profundo e aplicações ecológicas voltadas simultaneamente à vegetação, fauna e conservação ambiental. Além disso, a literatura disponível apresenta elevada heterogeneidade metodológica quanto aos sensores utilizados, algoritmos empregados, métricas de desempenho e escalas espaciais analisadas, dificultando comparações entre diferentes aplicações ambientais.

Diferentemente das revisões anteriores, este estudo integra aplicações de GeoAI multimodal no contexto amazônico, contemplando sensores ópticos, SAR, LiDAR, drones/UAS, dados ecológicos e arquiteturas avançadas de deep learning. Adicionalmente, incorpora avanços tecnológicos recentes publicados entre 2022 e 2026, incluindo aplicações voltadas ao monitoramento faunístico automatizado, integração multissensorial, desempenho quantitativo de modelos e desafios relacionados à interpretabilidade algorítmica, escalabilidade analítica e conservação ambiental em ecossistemas tropicais complexos.

Diante desse contexto, o presente estudo teve como objetivo realizar uma revisão sistemática da literatura científica sobre aplicações de geotecnologias e inteligência artificial no monitoramento da biodiversidade amazônica, com foco em sensoriamento remoto multimodal, integração de sensores ambientais, deep learning, monitoramento florestal, aplicações faunísticas e conservação ambiental em ecossistemas tropicais.

2. MATERIAL E MÉTODOS

2.1 Delineamento da revisão

O presente estudo consistiu em uma revisão sistemática da literatura científica sobre aplicações de geotecnologias e inteligência artificial no monitoramento da biodiversidade amazônica. A revisão foi conduzida com base nas recomendações do protocolo PRISMA 2020 (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), visando garantir maior transparência metodológica, rastreabilidade das etapas de seleção e reprodutibilidade do processo de revisão (Page et al. 2021).

Embora o protocolo desta revisão sistemática não tenha sido previamente registrado em plataformas específicas, como o PROSPERO, todas as etapas metodológicas foram conduzidas de acordo com as recomendações do protocolo PRISMA 2020, visando garantir transparência, rastreabilidade e reprodutibilidade do processo de seleção, elegibilidade e análise dos estudos incluídos.

A abordagem metodológica foi estruturada para identificar estudos relacionados à integração entre sensoriamento remoto, GeoAI, aprendizado de máquina e monitoramento ambiental em ecossistemas amazônicos e florestas tropicais comparáveis. O processo de revisão incluiu as etapas de identificação, triagem, elegibilidade e inclusão dos estudos selecionados.

2.2 Bases de dados

As buscas bibliográficas foram realizadas em abril de 2026, nas bases de dados Scopus, Web of Science, ScienceDirect, PubMed e IEEE Xplore, por apresentarem ampla cobertura de estudos relacionados às áreas de sensoriamento remoto, inteligência artificial, ecologia e monitoramento ambiental.

2.3 Estratégia de busca

A estratégia de busca foi elaborada com o objetivo de ampliar a recuperação de estudos relacionados ao monitoramento ambiental amazônico utilizando inteligência artificial e geotecnologias. Para isso, os descritores foram organizados em quatro blocos temáticos combinados por operadores booleanos.

O primeiro bloco contemplou termos relacionados à região de estudo: (“Amazon” OR “Amazon rainforest” OR “tropical forest”).

O segundo bloco incluiu termos associados à biodiversidade e monitoramento ambiental: (“biodiversity” OR “wildlife” OR “forest monitoring” OR “ecological monitoring”).

O terceiro bloco reuniu termos relacionados às geotecnologias e ao sensoriamento remoto: (“remote sensing” OR “LiDAR” OR “SAR” OR “drone” OR “UAS” OR “GIS”).

O quarto bloco contemplou termos relacionados à inteligência artificial e aprendizado de máquina: (“artificial intelligence” OR “machine learning” OR “deep learning” OR “convolutional neural network” OR “GeoAI”).

As combinações entre os descritores foram adaptadas conforme as especificidades de indexação e sintaxe de cada base de dados. As buscas foram realizadas considerando publicações disponíveis até abril de 2026.

2.4 Critérios de inclusão e exclusão

Foram incluídos na revisão estudos que atenderam aos seguintes critérios:

- i) estudos envolvendo aplicações de inteligência artificial, aprendizado de máquina, deep learning ou geotecnologias aplicadas ao monitoramento ambiental;
- ii) pesquisas relacionadas ao monitoramento da biodiversidade, dinâmica florestal, degradação ambiental, desmatamento, biomassa, fauna silvestre ou conservação em ambientes tropicais;
- iii) estudos conduzidos diretamente na Amazônia ou em florestas tropicais úmidas comparáveis, com aplicações metodológicas relevantes ao contexto amazônico;
- iv) artigos científicos revisados por pares publicados em periódicos indexados;
- v) publicações redigidas em inglês; e
- vi) estudos utilizando sensoriamento remoto, integração multimodal de sensores, LiDAR, SAR, drones/UAS, sistemas de informação geográfica ou técnicas de GeoAI aplicadas à análise ambiental.

Foram excluídos da revisão:

- i) estudos sem aplicação ambiental, ecológica ou relacionada ao monitoramento da biodiversidade;
- ii) pesquisas exclusivamente urbanas, agrícolas ou sem relação com ecossistemas florestais tropicais;
- iii) artigos puramente teóricos ou metodológicos sem aplicação prática em monitoramento ambiental;
- iv) estudos sem descrição metodológica clara ou sem informações suficientes para interpretação dos resultados;
- v) trabalhos duplicados entre as bases de dados consultadas;
- vi) documentos institucionais, websites e publicações não revisadas por pares, exceto preprints utilizados para contextualização tecnológica recente; e
- vii) estudos que não utilizaram técnicas de inteligência artificial, aprendizado de máquina ou geotecnologias relacionadas ao escopo da revisão.

2.5 Processo de seleção dos estudos

O processo de seleção dos estudos foi conduzido conforme as recomendações do protocolo PRISMA 2020 (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), visando garantir transparência metodológica, rastreabilidade das etapas de seleção e maior reprodutibilidade da revisão sistemática. Embora o protocolo desta revisão não tenha sido previamente registrado em plataformas específicas, como o PROSPERO, todas as etapas metodológicas seguiram rigorosamente as recomendações propostas por Page et al. (2021).

As buscas realizadas nas bases Scopus, Web of Science, ScienceDirect, PubMed e IEEE Xplore resultaram em 186 registros científicos. Desse total, 74 registros foram identificados na Scopus, 41 na Web of Science, 36 na ScienceDirect, 18 na PubMed e 17 na IEEE Xplore. Todos os registros foram consolidados em planilha única para organização, padronização dos dados e identificação de duplicatas.

Após a remoção de 38 registros duplicados, permaneceram 148 estudos para a etapa de triagem. Nessa fase, títulos e resumos foram avaliados conforme os critérios de inclusão e exclusão previamente estabelecidos. Foram excluídos 79 estudos por não apresentarem relação direta com monitoramento da biodiversidade, geotecnologias ou aplicações de inteligência artificial voltadas ao contexto ambiental amazônico.

Ao final da triagem inicial, 69 estudos permaneceram elegíveis para leitura completa. Durante a etapa de elegibilidade, os artigos foram avaliados integralmente quanto à adequação temática, qualidade metodológica e alinhamento com os objetivos da revisão. Para reduzir subjetividades no processo de seleção, o critério “ecossistemas tropicais comparáveis” foi delimitado exclusivamente a estudos conduzidos em florestas tropicais úmidas com características ecológicas semelhantes às da Amazônia, envolvendo aplicações relacionadas ao monitoramento da biodiversidade, dinâmica florestal, degradação ambiental ou modelagem ecológica.

Nessa etapa, 34 estudos foram excluídos pelos seguintes motivos: i) ausência de aplicação relacionada à biodiversidade (n = 10); ii) ausência de técnicas de inteligência artificial ou geotecnologias (n = 8); iii) foco exclusivamente metodológico sem aplicação ambiental direta (n = 6); iv) ausência de relação com ambientes tropicais ou amazônicos (n = 6); e v) insuficiência metodológica ou indisponibilidade do texto completo (n = 4).


Ao final do processo de seleção, 35 estudos compuseram a amostra final da revisão sistemática. Adicionalmente, uma referência metodológica foi utilizada exclusivamente para orientar a aplicação e descrição do protocolo PRISMA 2020 (Page et al., 2021), não sendo incluída na síntese analítica dos resultados.

Dos estudos incluídos na revisão, 18 (51,4%) foram conduzidos diretamente na Amazônia ou em florestas amazônicas específicas, abordando temas relacionados ao desmatamento, degradação florestal, biomassa, estrutura da vegetação, biodiversidade e monitoramento faunístico. Os demais 17 estudos (48,6%) corresponderam a aplicações desenvolvidas em outros ecossistemas tropicais, revisões metodológicas ou trabalhos conceituais envolvendo inteligência artificial, sensoriamento remoto e GeoAI aplicados ao monitoramento ambiental. A inclusão desses estudos complementares buscou ampliar a compreensão das abordagens metodológicas, arquiteturas computacionais e integrações multimodais de sensores potencialmente aplicáveis ao contexto amazônico.

A triagem dos estudos, a avaliação da elegibilidade e a extração de dados foram realizadas por um único revisor. Devido a limitações de recursos, a triagem independente por dois revisores não foi viável. Para minimizar o potencial viés de seleção, os critérios de elegibilidade predefinidos foram rigorosamente aplicados em todas as etapas do processo de revisão, e o procedimento de seleção dos estudos foi totalmente documentado de acordo com as recomendações do PRISMA 2020.

O fluxograma detalhado contendo as etapas de identificação, triagem, elegibilidade e inclusão, bem como o número de registros excluídos em cada fase e seus respectivos motivos, é apresentado na Figura 1, elaborada conforme o modelo PRISMA 2020 proposto por Page et al. (2021).

Figura 1. Fluxograma PRISMA 2020 para seleção dos estudos incluídos na revisão sistemática



Fonte: Adaptado de Page et al. 2021

2.6 Extração de dados

Os estudos incluídos na revisão foram analisados por meio de extração padronizada de informações metodológicas e técnicas relevantes aos objetivos da pesquisa. Foram extraídas informações relacionadas aos sensores utilizados, algoritmos empregados, aplicações ambientais, métricas de desempenho e escalas espaciais dos estudos selecionados. Entre os principais sensores identificados destacaram-se plataformas Sentinel, LiDAR, drones/UAS e SAR, enquanto os algoritmos mais frequentes incluíram redes neurais convolucionais (CNN), Random Forest, Support Vector Machine (SVM) e abordagens baseadas em deep learning. As aplicações analisadas envolveram principalmente biomassa, monitoramento faunístico, queimadas, degradação florestal e mudanças no uso da terra. As métricas de desempenho mais reportadas incluíram acurácia, F1-score e área sob a curva ROC (AUC), considerando aplicações em escalas locais, regionais e continentais.

Além dessas variáveis, também foram extraídas informações relacionadas ao ano de publicação, objetivos dos estudos, áreas de aplicação e principais limitações metodológicas reportadas pelos autores.

2.7 Avaliação da qualidade metodológica

A qualidade metodológica dos estudos selecionados foi avaliada usando uma estrutura de pontuação adaptada, desenvolvida para pesquisas envolvendo GeoAI, sensoriamento remoto e monitoramento ambiental em ecossistemas tropicais. A avaliação teve como objetivo avaliar a robustez metodológica, a transparência analítica, a reprodutibilidade computacional e a aplicabilidade ecológica dos estudos incluídos nesta revisão sistemática.

Devido à ausência de uma ferramenta validada de avaliação de risco de viés, especificamente projetada para estudos envolvendo GeoAI, inteligência artificial e sensoriamento remoto ambiental, uma estrutura metodológica personalizada foi adotada. Essa estrutura foi baseada em domínios comumente empregados em revisões de inteligência artificial ambiental, análises geoespaciais e aplicações de sensoriamento remoto, incluindo transparência metodológica, qualidade e descrição dos dados, procedimentos de validação, reprodutibilidade e robustez do modelo. Abordagens adaptadas semelhantes têm sido empregadas em campos interdisciplinares emergentes, onde instrumentos padronizados de avaliação de qualidade ainda não estão disponíveis.

A estrutura adotada foi projetada para acomodar a heterogeneidade metodológica característica dos estudos de GeoAI, particularmente em relação às diferenças nos tipos de sensores, escalas espaciais, arquiteturas computacionais, estratégias de validação e métricas de desempenho. Essa abordagem possibilitou uma avaliação comparativa mais adequada de estudos que abordam o monitoramento ambiental e a conservação da biodiversidade na região amazônica.

Cinco critérios metodológicos foram avaliados: (i) clareza metodológica; (ii) qualidade e descrição dos conjuntos de dados; (iii) relato de métricas quantitativas de desempenho; (iv) reprodutibilidade computacional; e (v) aplicabilidade ecológica ao contexto amazônico. Cada critério recebeu uma pontuação que variava de 1 a 3, onde 1 indicava relato insuficiente, 2 indicava relato parcial ou moderadamente adequado e 3 indicava relato abrangente, transparente e reprodutível.

Todos os critérios receberam pesos iguais para garantir uma avaliação equilibrada do rigor metodológico, da transparência analítica e da relevância ecológica. A pontuação total variou de 5 a 15 pontos, permitindo que os estudos fossem classificados em três categorias de qualidade metodológica: baixa qualidade (5–7 pontos), qualidade moderada (8–11 pontos) e alta qualidade (12–15 pontos).

De modo geral, observou-se predominância de estudos classificados com alta qualidade metodológica, especialmente aqueles baseados em integração multimodal de sensores, validação quantitativa robusta e arquiteturas avançadas de deep learning. As principais limitações identificadas envolveram ausência de validação externa independente, descrição insuficiente dos conjuntos de treinamento e limitações relacionadas à reprodutibilidade computacional em parte das aplicações analisadas.

2.8 Limitações metodológicas

A presente revisão sistemática apresenta algumas limitações metodológicas que devem ser consideradas na interpretação dos resultados. A seleção dos estudos, aplicação dos critérios de elegibilidade e extração dos dados foram conduzidas por revisora única, o que pode introduzir potencial subjetividade no processo de avaliação e síntese das informações. Entretanto, buscou-se minimizar possíveis vieses mediante aplicação padronizada dos

critérios metodológicos e adoção das recomendações estabelecidas pelo protocolo PRISMA 2020.

Além disso, o protocolo da revisão não foi previamente registrado em plataformas específicas, como PROSPERO, devido ao caráter interdisciplinar, tecnológico e ambiental da pesquisa, área em que esse tipo de registro ainda é relativamente pouco utilizado. Também foram observadas limitações relacionadas à heterogeneidade metodológica dos estudos incluídos, especialmente quanto às métricas de desempenho reportadas, estratégias de validação dos modelos e diversidade de sensores empregados, dificultando comparações quantitativas diretas entre diferentes aplicações de GeoAI no contexto amazônico.

2.9 Uso de inteligência artificial

Ferramentas baseadas em inteligência artificial generativa, incluindo o ChatGPT, desenvolvido pela OpenAI, foram utilizadas exclusivamente para apoio linguístico, revisão gramatical, organização textual preliminar e auxílio na padronização da redação científica. Todas as etapas relacionadas à definição metodológica, seleção dos estudos, extração de dados, análise crítica, interpretação científica e redação final foram conduzidas integralmente pela autora.

Nenhuma ferramenta de inteligência artificial foi utilizada para geração automática de resultados, interpretação científica, análise dos dados ou tomada de decisão metodológica.

3. RESULTADOS

3.1 Caracterização geral da literatura selecionada

Após a aplicação dos critérios de inclusão e exclusão conforme as recomendações do protocolo PRISMA 2020, foram selecionados 35 estudos para compor a amostra final da revisão sistemática. Adicionalmente, uma referência metodológica foi utilizada exclusivamente para orientar a aplicação e descrição do protocolo PRISMA (Page et al., 2021), não sendo incluída na síntese analítica dos resultados.

As principais características dos estudos incluídos, incluindo região de estudo, sensores utilizados, abordagens computacionais e aplicações ambientais investigadas, encontram-se sintetizadas na Tabela 1.

Tabela 1. Características dos estudos incluídos na revisão sistemática

Autor	Região de estudo	Sensor/Geotecnologia	Algoritmo/Abordagem	Aplicação principal
Turner et al. (2003)	Global	Sensoriamento remoto	Revisão conceitual	Conservação da biodiversidade
Morton et al. (2006)	Amazônia brasileira	Landsat	Análise espacial	Dinâmica do desmatamento
Malhi et al. (2008)	Amazônia	Modelagem climática	Análise integrada	Mudanças climáticas e desmatamento
Asner et al. (2010)	Amazônia	LiDAR aerotransportado	Integração geoespacial	Biomassa e carbono florestal
Garda et al. (2010)	Amazônia	Revisão ecológica	Análise conceitual	Conservação da biodiversidade
Hansen et al. (2013)	Global/Amazônia	Landsat	Classificação temporal	Mudanças da cobertura florestal
Pettorelli et al. (2014)	Global	Sensoriamento remoto orbital	Revisão metodológica	Ecologia aplicada
Gómez-Chova et al. (2015)	Global	Sensoriamento remoto multimodal	Classificação multimodal	Integração de dados geoespaciais
Skidmore et al.	Global	Sensoriamento remoto	Análise conceitual	Métricas de

(2015)				biodiversidade
Nobre et al. (2016)	Amazônia	Modelagem ambiental	Cenários integrados	Sustentabilidade amazônica
Bush et al. (2017)	Global	Observação da Terra	Integração de dados	Biodiversidade e Earth Observation
Fearnside (2017)	Amazônia brasileira	Sensoriamento remoto	Revisão temática	Desmatamento amazônico
Lovejoy (2017)	Amazônia	Revisão ecológica	Análise conceitual	Conservação amazônica
Zhu et al. (2017)	Global	Sensoriamento remoto	Deep Learning	Revisão de IA aplicada
Norouzzadeh et al. (2018)	Global	Armadilhas fotográficas	Deep CNN	Reconhecimento automatizado de fauna
Willi et al. (2018)	Global	Camera traps	Deep Learning	Monitoramento faunístico
Reichstein et al. (2019)	Global	Dados ambientais	Deep Learning	Ciências do sistema terrestre
Norouzzadeh et al. (2019)	Global	Camera traps	Machine Learning	Classificação automática de espécies
Assis et al. (2020)	Amazônia brasileira	Sensoriamento remoto	Modelagem espacial	Emissões por degradação florestal
Khelifi e Mignotte (2020)	Global	Sensoriamento remoto	Deep Learning	Deteção de mudanças ambientais
Ball et al. (2022)	Amazônia brasileira	Séries temporais de satélite	CNN	Previsão de desmatamento
Besson et al. (2022)	Global	Sensores ecológicos	IA automatizada	Monitoramento ecológico
Dalagnol et al. (2022)	Amazônia brasileira	LiDAR aerotransportado	Deep Learning	Mapeamento de palmeiras
Kim et al. (2022)	Amazônia	Imagens digitais	CNN	Classificação de papagaios amazônicos
Veras et al. (2022)	Amazônia brasileira	UAS/Drones	CNN	Classificação de espécies arbóreas
Lapola et al. (2023)	Amazônia	Dados multissensoriais	Síntese integrada	Degradação florestal
Fergus et al. (2024)	Global	Dados ecológicos	Inteligência Artificial	Conservação da fauna
Guayasamin et al. (2024)	Amazônia	Revisão biogeográfica	Síntese integrativa	Biodiversidade amazônica
Karpatne et al. (2024)	Global	Dados ambientais	Knowledge-guided ML	IA ambiental
Tuia et al. (2024)	Global	Observação da Terra	Inteligência Artificial	GeoAI e Earth Observation
Lopes et al. (2025)	Amazônia Central	LiDAR multitemporal	Modelagem estrutural	Impactos de incêndios
Mataveli et al. (2025)	Amazônia	Sensoriamento remoto multimodal	Machine Learning	Degradação florestal
Dal Molin et al. (2026)	Floresta tropical	Sentinel-1 SAR	Deep Learning	Monitoramento florestal
Lei et al. (2026)	Global	Sensoriamento remoto	Deep Learning	Deteção de mudanças
Valle et al. (2026)	Amazônia brasileira	LiDAR + Sentinel	Deep Learning multimodal	Estrutura vertical florestal


Fonte: Autora (2026)

Entre os estudos analisados, 18 (51,4%) foram conduzidos diretamente na Amazônia ou em florestas amazônicas específicas, enquanto 17 estudos (48,6%) corresponderam a revisões metodológicas, aplicações em florestas tropicais comparáveis ou estudos conceituais relacionados à inteligência artificial, sensoriamento remoto e GeoAI aplicados ao monitoramento ambiental.

Conforme observado na Tabela 2, houve predominância de estudos voltados ao monitoramento florestal, detecção de desmatamento e caracterização da vegetação, com crescente utilização de técnicas de deep learning associadas a dados LiDAR, imagens de satélite e veículos aéreos não tripulados.

Observou-se crescimento expressivo da produção científica a partir de 2020, conforme demonstrado na Figura 2, com maior concentração de publicações entre 2022 e 2026. Esse aumento evidencia a rápida expansão das aplicações de GeoAI e aprendizado profundo voltadas ao monitoramento ambiental tropical. Os estudos mais recentes apresentaram maior diversidade metodológica, incorporando processamento em nuvem, análise multitemporal e integração entre diferentes fontes de dados ambientais.

Figura 2. Distribuição temporal dos estudos incluídos na revisão sistemática sobre aplicações de GeoAI e inteligência artificial no monitoramento ambiental amazônico



Fonte: Autora 2026

As escalas espaciais analisadas variaram desde aplicações locais baseadas em drones/UAS, armadilhas fotográficas e levantamentos LiDAR aerotransportados até estudos regionais e continentais utilizando imagens orbitais multitemporais. Aproximadamente 51,4% dos estudos envolveram análises regionais, 31,4% aplicações locais em alta resolução espacial e 17,1% abordagens continentais ou pan-amazônicas.

Também foi observada expansão progressiva da integração entre abordagens ecológicas e computacionais, principalmente em estudos voltados ao monitoramento automatizado da biodiversidade, degradação florestal e dinâmica da vegetação amazônica. Estudos publicados após 2022 apresentaram maior utilização de estratégias de fusão de dados ambientais e arquiteturas profundas aplicadas ao processamento geoespacial em larga escala.

A literatura analisada demonstrou predominância de aplicações direcionadas à vegetação e estrutura florestal, enquanto estudos relacionados ao monitoramento integrado da fauna, conectividade ecológica e interações ecológicas complexas permaneceram menos frequentes. Esse padrão indica que, embora o avanço tecnológico tenha sido significativo nos

últimos anos, ainda persistem lacunas importantes em aplicações voltadas diretamente à biodiversidade amazônica em sentido amplo.

3.2 Avaliação metodológica dos estudos

A avaliação metodológica dos estudos incluídos foi realizada com base em critérios relacionados à clareza metodológica, descrição dos dados utilizados, validação analítica, reprodutibilidade computacional e robustez dos modelos empregados.

Observou-se predominância de estudos classificados como de alta e moderada qualidade metodológica. Do total de 35 estudos analisados, 18 (51,4%) foram classificados como de alta qualidade metodológica, 12 (34,3%) como qualidade moderada e cinco (14,3%) como baixa qualidade metodológica.

Os estudos classificados com maior qualidade metodológica apresentaram descrição detalhada dos dados utilizados, maior transparência analítica, métricas quantitativas robustas e melhor potencial de reprodutibilidade computacional. Essas pesquisas também demonstraram maior clareza quanto à validação dos modelos, descrição dos conjuntos de treinamento e discussão das limitações metodológicas.

Por outro lado, os estudos classificados com menor qualidade metodológica frequentemente apresentaram ausência de validação estatística detalhada, descrição insuficiente dos dados de treinamento e baixa transparência quanto aos parâmetros computacionais empregados, limitando parcialmente a replicação dos experimentos.

A avaliação metodológica também evidenciou elevada heterogeneidade entre protocolos de treinamento, estratégias de validação, seleção de variáveis ambientais e métricas de desempenho, indicando ausência de padronização metodológica consolidada para aplicações de GeoAI voltadas ao monitoramento ambiental amazônico.

Além dos estudos empíricos diretamente aplicados ao contexto amazônico, a revisão também incorporou estudos conceituais e metodológicos utilizados para contextualização teórica, computacional e tecnológica das abordagens de GeoAI identificadas na literatura.

3.3 Sensores e geotecnologias empregados nos estudos

Sensores ópticos de satélite foram as tecnologias mais frequentemente utilizadas entre os estudos selecionados, aparecendo em 27 das 35 publicações analisadas (77,1%). As plataformas mais comumente relatadas foram Landsat e Sentinel-2, que foram aplicadas ao monitoramento da cobertura vegetal, detecção de desmatamento e análises de mudanças no uso da terra.

Dados LiDAR foram identificados em 14 estudos (40,0%). Esses estudos empregaram conjuntos de dados LiDAR aerotransportados para aplicações envolvendo estimativa de biomassa, caracterização da estrutura da vegetação, modelagem florestal tridimensional e avaliação da estrutura vertical da floresta.

Dados de Radar de Abertura Sintética (SAR) foram relatados em 11 estudos (31,4%), sendo o Sentinel-1 a plataforma de radar mais frequentemente utilizada. Os conjuntos de dados SAR foram aplicados principalmente ao monitoramento ambiental e análises multitemporais.

Sistemas Aéreos Não Tripulados (UAS) ou drones foram utilizados em oito estudos (22,9%). Suas aplicações incluíram classificação da vegetação, mapeamento de espécies arbóreas, monitoramento da fauna e aquisição de imagens de alta resolução.


Observou-se uma crescente adoção de conjuntos de dados ambientais integrados em estudos publicados após 2022. Esses estudos combinaram dados ópticos, SAR, LiDAR e derivados de drones para apoiar análises ambientais em diferentes escalas espaciais e temporais.

Publicações recentes também relataram o uso crescente de plataformas geoespaciais baseadas em nuvem, conjuntos de dados de séries temporais ambientais e fluxos de trabalho automatizados de processamento de dados para monitoramento ambiental em larga escala.

3.4 Aplicações de GeoAI no monitoramento da biodiversidade amazônica

A análise temática dos estudos revelou predominância de aplicações voltadas ao monitoramento de desmatamento e degradação florestal, seguidas por pesquisas relacionadas à biomassa, biodiversidade e integração multissensorial (Figura 3).

Figura 3. Distribuição temática dos estudos incluídos na revisão sistemática sobre aplicações de GeoAI no monitoramento ambiental amazônico



Fonte: Autora 2026

O monitoramento de desmatamento e mudanças no uso da terra representou a aplicação mais frequente, presente em 16 estudos (45,7%). Essas pesquisas utilizaram predominantemente imagens Landsat, Sentinel e dados SAR associados a modelos automatizados de classificação e detecção de mudanças ambientais.

Aplicações relacionadas à biomassa, estoque de carbono e estrutura florestal foram identificadas em 12 estudos (34,3%), principalmente associadas ao uso de dados LiDAR e imagens orbitais multitemporais. Os estudos concentraram-se em estimativas estruturais da vegetação, caracterização do dossel e modelagem da heterogeneidade florestal.

O monitoramento de degradação florestal e queimadas esteve presente em 10 estudos (28,6%), com predominância de séries temporais multissensores aplicadas à identificação de alterações estruturais da vegetação. Parte dos estudos abordou processos de degradação fina e impactos ambientais sutis não detectados por abordagens convencionais baseadas exclusivamente em sensores ópticos.

Aplicações voltadas ao monitoramento faunístico automatizado e reconhecimento de espécies foram identificadas em oito estudos (22,9%). Essas pesquisas utilizaram principalmente armadilhas fotográficas automatizadas, imagens digitais e técnicas de visão computacional para classificação automatizada da fauna amazônica. Estudos envolvendo bioacústica ainda permaneceram pouco representados na literatura analisada.

Também foram identificadas aplicações relacionadas à classificação automatizada de espécies arbóreas, conservação ambiental e monitoramento ecológico em larga escala,

frequentemente associadas ao uso de drones/UAS, plataformas orbitais e sistemas geoespaciais integrados.

De forma geral, os estudos evidenciaram expansão progressiva das aplicações de GeoAI no monitoramento ambiental amazônico, especialmente após 2022, com ampliação do uso de sensores multissensoriais, arquiteturas profundas de aprendizado e plataformas automatizadas de processamento geoespacial.

3.5 Algoritmos de inteligência artificial utilizados

Os algoritmos de aprendizado profundo representaram a principal abordagem metodológica identificada nos estudos selecionados. Redes neurais convolucionais (CNNs) estiveram presentes em 17 estudos (48,6%), principalmente em aplicações relacionadas à classificação de imagens, segmentação ambiental, detecção de mudanças na cobertura vegetal e reconhecimento automatizado de espécies.

Modelos Random Forest foram identificados em 10 estudos (28,6%), sendo amplamente empregados em tarefas de classificação ambiental, modelagem espacial e estimativas de variáveis ecológicas. Máquinas de Vetores de Suporte (SVM) estiveram presentes em seis estudos (17,1%), sobretudo em aplicações envolvendo conjuntos de dados menores e classificação supervisionada.

Observou-se crescimento expressivo, principalmente após 2022, da utilização de arquiteturas profundas aplicadas ao processamento geoespacial, incluindo modelos voltados à análise multitemporal, aprendizado espacial e reconhecimento automatizado de padrões ambientais complexos. Esse avanço evidenciou transição progressiva de abordagens convencionais de machine learning para estratégias mais sofisticadas de deep learning aplicadas ao monitoramento ambiental tropical.

Os maiores desempenhos analíticos foram reportados em estudos que integraram arquiteturas profundas, dados ambientais multitemporais e sensores de alta resolução espacial, especialmente em aplicações relacionadas à degradação florestal, biomassa e dinâmica da vegetação. Também foi observada ampliação do uso de técnicas de visão computacional, aprendizado supervisionado automatizado e plataformas de processamento em nuvem para operacionalização de modelos em larga escala.

Estudos recentes passaram a incorporar estratégias de fusão temporal e espacial de dados ambientais, favorecendo aplicações preditivas relacionadas à dinâmica florestal, monitoramento quase em tempo real e modelagem ambiental integrada. Apesar dos avanços observados, persistem desafios relacionados à reprodutibilidade computacional, disponibilidade de bases de treinamento representativas e transferência dos modelos para diferentes regiões ecológicas da Amazônia.

3.6 Métricas de desempenho dos modelos

Os estudos analisados apresentaram considerável heterogeneidade quanto às métricas utilizadas para avaliação dos modelos de inteligência artificial aplicados ao monitoramento ambiental amazônico. As métricas mais frequentemente reportadas incluíram acurácia, F1-score, coeficiente Kappa, área sob a curva ROC (AUC) e coeficiente de determinação (R^2), evidenciando diversidade metodológica entre os protocolos de validação empregados. A Tabela 2 apresenta uma síntese das principais métricas de desempenho reportadas pelos estudos empíricos incluídos nesta revisão.

Tabela 2. Métricas de desempenho reportadas pelos estudos de GeoAI incluídos na revisão sistemática

Referência	Aplicação	Sensor/Fonte de Dados	Algoritmo	Acurácia (%)	F1-score	AUC	Outras Métricas
Ball et al. (2022)	Previsão de desmatamento	Séries temporais Sentinel/Landsat	CNN	—	—	0,91	—

Dalagnol et al. (2022)	Mapeamento de palmeiras	LiDAR aerotransportado	Aprendizado Profundo (Deep Learning)	> 89	—	—	—
Veras et al. (2022)	Classificação de espécies arbóreas	Imagens obtidas por UAS (drone)	CNN	> 92	—	—	—
Kim et al. (2022)	Classificação de papagaios amazônicos	Imagens digitais	CNN	—	> 0,90	—	—
Norouzzadeh et al. (2018)	Reconhecimento automatizado de fauna	Armadilhas fotográficas (camera traps)	Deep Learning	—	> 0,90	—	—
Valle et al. (2026)	Caracterização da estrutura vertical da floresta	LiDAR + Sentinel	Deep Learning	—	—	—	R ² > 0,89
Dal Molin et al. (2026)	Monitoramento de florestas tropicais	Sentinel-1 SAR	Deep Learning	—	> 0,90	—	—

Fonte: Autora (2026)

Entre os estudos que reportaram métricas quantitativas de desempenho, observou-se desempenho geralmente elevado dos modelos empregados, especialmente em aplicações relacionadas à detecção de desmatamento, monitoramento florestal, caracterização da vegetação e reconhecimento automatizado de espécies. Entretanto, a comparação direta entre os resultados foi limitada pela diversidade de conjuntos de dados, objetivos analíticos, escalas espaciais e estratégias de validação adotadas pelos diferentes estudos.

Ball et al. (2022), por exemplo, reportaram AUC de 0,91 na previsão espacial de desmatamento utilizando redes neurais convolucionais aplicadas a séries temporais de imagens Sentinel e Landsat. Em aplicações voltadas à estimativa de biomassa e estrutura florestal, estudos baseados em dados LiDAR e abordagens de aprendizado profundo também demonstraram elevado desempenho preditivo.

Valle et al. (2026) obtiveram coeficientes de determinação superiores a 0,89 na modelagem da estrutura vertical da floresta amazônica por meio da integração entre dados LiDAR e Sentinel, enquanto Dalagnol et al. (2022) reportaram acurácia superior a 89% no mapeamento automatizado de palmeiras utilizando aprendizado profundo associado a dados LiDAR aerotransportados.

Em estudos relacionados ao monitoramento faunístico, modelos de visão computacional aplicados a armadilhas fotográficas e imagens digitais demonstraram elevada capacidade de identificação automatizada de espécies. Kim et al. (2022) e Norouzzadeh et al. (2018) reportaram F1-scores superiores a 0,90 em aplicações de reconhecimento automatizado de fauna, alcançando desempenhos comparáveis aos obtidos por especialistas humanos.

Da mesma forma, Veras et al. (2022) observaram acurácia superior a 92% na classificação de espécies arbóreas utilizando redes neurais convolucionais aplicadas a imagens multissazonais obtidas por drones. Aplicações envolvendo monitoramento florestal tropical e degradação ambiental também apresentaram desempenho promissor em modelos desenvolvidos com dados SAR e informações multissensoriais.

Dal Molin et al. (2026) reportaram F1-scores superiores a 0,90 na detecção de alterações estruturais em florestas tropicais utilizando dados Sentinel-1 SAR, enquanto Mataveli et al. (2025) observaram elevada capacidade de detecção de degradação florestal amazônica por meio de modelos de machine learning aplicados a dados multissensoriais.

Os resultados evidenciaram que abordagens baseadas na integração temporal, espacial e multissensorial ampliam significativamente a capacidade de detecção de padrões ecológicos e estruturais em ecossistemas amazônicos. Em contrapartida, aplicações relacionadas à conectividade ecológica, modelagem faunística e interações ecológicas complexas ainda apresentaram elevada heterogeneidade metodológica, reduzida padronização analítica e variabilidade considerável entre métricas e protocolos de validação.

Observou-se ainda que aproximadamente 42,9% dos estudos analisados não realizaram validação externa independente dos modelos desenvolvidos, limitando parcialmente a capacidade de generalização dos resultados obtidos. Além disso, diferenças entre métricas de desempenho, estratégias de treinamento, escalas espaciais e procedimentos de validação dificultaram comparações diretas entre diferentes algoritmos e aplicações ambientais reportadas na literatura.

A comparação quantitativa abrangente entre todos os estudos não foi possível devido à ausência de padronização nas métricas reportadas e à elevada heterogeneidade metodológica observada entre as pesquisas incluídas. Dessa forma, a síntese apresentada concentrou-se nas métricas efetivamente reportadas pelos estudos empíricos analisados.

Entre as principais limitações metodológicas identificadas destacaram-se a baixa disponibilidade de dados rotulados, a reduzida representatividade de determinadas regiões amazônicas nos conjuntos de treinamento, a elevada heterogeneidade ambiental e a persistente influência da cobertura de nuvens em sensores ópticos. Apesar dessas limitações, os estudos mais recentes indicaram expansão da integração entre séries temporais ambientais, plataformas geoespaciais e arquiteturas profundas de aprendizado, ampliando o potencial de precisão, automação e escalabilidade das aplicações de GeoAI no monitoramento da biodiversidade amazônica.

3.7 Lacunas científicas, desafios e tendências emergentes

A revisão evidenciou importantes lacunas científicas relacionadas à aplicação de GeoAI no monitoramento da biodiversidade amazônica. Embora tenham sido observados avanços significativos em monitoramento de desmatamento, biomassa e degradação florestal, aplicações voltadas ao monitoramento integrado da fauna, conectividade ecológica e modelagem de interações ecológicas complexas ainda permaneceram limitadas.

Apenas cinco estudos discutiram explicitamente interpretabilidade algorítmica, enquanto quatro abordaram potenciais vieses amostrais e somente três relacionaram diretamente os resultados ao planejamento ambiental e formulação de políticas públicas. Esses resultados demonstram que questões relacionadas à transparência algorítmica, ética computacional e aplicabilidade prática ainda permanecem subexploradas na literatura analisada.

Também foram identificadas limitações associadas à escassez de dados de treinamento em regiões remotas da Amazônia, elevada heterogeneidade ambiental, persistente cobertura de nuvens e custos operacionais relacionados à aquisição de dados LiDAR de alta resolução.

Apesar dessas limitações, observou-se tendência crescente de integração entre inteligência artificial, sensoriamento remoto e plataformas geoespaciais em nuvem. Estudos recentes demonstraram expansão do uso de arquiteturas profundas, processamento automatizado em larga escala e aplicações voltadas ao monitoramento quase em tempo real de ecossistemas amazônicos.

Além disso, abordagens emergentes envolvendo edge AI, automação ecológica, aprendizado profundo multimodal e integração entre dados ecológicos e geoespaciais indicam perspectivas promissoras para aplicações futuras em conservação da biodiversidade, manejo florestal sustentável e monitoramento ambiental amazônico.

4. DISCUSSÃO


4.1 Avanços da GeoAI no monitoramento ambiental amazônico

Os estudos analisados evidenciaram que a integração entre inteligência artificial, sensoriamento remoto e geotecnologias vem ampliando significativamente a capacidade de monitoramento ambiental da Amazônia, especialmente em aplicações relacionadas à detecção de desmatamento, degradação florestal, biomassa, estrutura da vegetação e biodiversidade. A predominância recente de arquiteturas profundas demonstra transição metodológica importante em relação às abordagens convencionais de análise espacial e ecológica.

Estudos conceituais indicam que a convergência entre aprendizado profundo, computação espacial e observação da Terra favorece análises automatizadas de sistemas ecológicos complexos e maior integração entre sensores ambientais, modelagem espacial e inteligência computacional (Zhu et al. 2017; Reichstein et al. 2019; Tuia et al. 2024). Nesse contexto, a GeoAI vem sendo consolidada como estrutura analítica integrada para interpretação de padrões ambientais e apoio à tomada de decisão ambiental em larga escala.

A Figura 4 sintetiza os principais componentes tecnológicos identificados nos estudos analisados, incluindo sensores ambientais, técnicas de inteligência artificial e aplicações ecológicas voltadas ao monitoramento da biodiversidade e dinâmica ambiental amazônica.

Figura 4. Framework conceitual da integração entre GeoAI, sensoriamento remoto e monitoramento ambiental amazônico



Fonte: Autora 2026

Os estudos que integraram arquiteturas profundas, séries temporais e sensores de alta resolução apresentaram os melhores desempenhos analíticos, principalmente em aplicações relacionadas à degradação florestal, biomassa e mudanças de cobertura vegetal (Ball et al. 2022; Dalagnol et al. 2022; Dal Molin et al. 2026; Valle et al. 2026). Em comparação aos algoritmos tradicionais, os modelos profundos demonstraram maior capacidade de generalização espacial em ambientes caracterizados por elevada heterogeneidade ambiental.

Além do desempenho superior em tarefas de classificação ambiental, observou-se avanço recente de aplicações preditivas relacionadas à dinâmica florestal e mudanças no uso

da terra. Ball et al. (2022), por exemplo, demonstraram que redes neurais convolucionais podem prever padrões espaciais de desmatamento amazônico com elevado desempenho, ampliando o potencial de aplicações preventivas voltadas à conservação ambiental e fiscalização territorial.

Outro aspecto relevante refere-se à crescente automatização dos processos analíticos em ecologia e sensoriamento remoto. A incorporação de técnicas de visão computacional, plataformas de processamento em nuvem e integração multissensorial vem favorecendo aplicações em larga escala e monitoramento quase em tempo real.

Apesar dos avanços observados, persistem limitações relacionadas à disponibilidade de bases de treinamento representativas, reprodutibilidade computacional e transferência dos modelos entre diferentes regiões ecológicas da Amazônia. Aplicações dependentes exclusivamente de sensores ópticos continuaram apresentando limitações operacionais associadas à elevada cobertura de nuvens e sazonalidade climática, reforçando a importância da integração entre sensores ópticos, SAR e LiDAR.

Os resultados também evidenciaram expansão expressiva das publicações nos últimos anos, indicando consolidação progressiva da GeoAI como área estratégica para monitoramento ambiental tropical, especialmente diante das demandas relacionadas à conservação da biodiversidade, monitoramento climático e redução das emissões associadas ao desmatamento amazônico.

Apesar da rápida expansão das aplicações de GeoIA no monitoramento ambiental da Amazônia, importantes lacunas conceituais e relacionadas à governança ainda persistem. Entre os 35 estudos revisados, apenas cinco discutiram explicitamente a interpretabilidade dos modelos, quatro abordaram potenciais vieses algorítmicos e somente três vincularam diretamente suas descobertas a políticas ambientais ou processos de tomada de decisão. Esses resultados sugerem que a pesquisa atual permanece predominantemente focada no desempenho técnico, enquanto questões relacionadas à explicabilidade, transparência, implicações éticas e integração de políticas recebem atenção comparativamente limitada. Expandir essas dimensões pode ser essencial para melhorar a confiabilidade, a aceitação e a implementação prática de sistemas de GeoIA na conservação da biodiversidade e na governança ambiental.

4.2 Integração multimodal e sensores ambientais

Os resultados desta revisão indicam que a integração multimodal emergiu como um dos avanços metodológicos mais importantes no monitoramento ambiental da Amazônia. Em vez de depender de uma única fonte de informação, estudos recentes combinam cada vez mais imagens ópticas, dados SAR, medições LiDAR e plataformas aéreas para capturar atributos ecológicos complementares em diferentes escalas espaciais e temporais. Essa integração aprimora a representação da estrutura florestal, da dinâmica da vegetação e das perturbações ambientais, proporcionando uma compreensão mais abrangente dos processos ecossistêmicos.

A superioridade das abordagens multimodais observada em diversos estudos pode ser amplamente atribuída à sua capacidade de superar as limitações associadas a sensores individuais. As imagens ópticas fornecem informações espectrais detalhadas para a classificação da cobertura do solo, enquanto os dados SAR permanecem eficazes sob cobertura de nuvens persistente e condições atmosféricas adversas, comuns em ambientes tropicais. O LiDAR contribui com informações exclusivas sobre a estrutura vertical da floresta e a distribuição da biomassa, enquanto as plataformas baseadas em drones oferecem altíssima resolução espacial para avaliações ecológicas locais. Consequentemente, a combinação desses conjuntos de dados complementares melhora a caracterização ambiental e aumenta a confiabilidade dos sistemas de monitoramento.

A literatura analisada também sugere que a integração multimodal é particularmente valiosa para detectar formas sutis e progressivas de degradação ambiental que muitas vezes são negligenciadas pelas abordagens de monitoramento convencionais. A combinação de informações temporais e estruturais permite a identificação de mudanças associadas à exploração seletiva de madeira, impactos de incêndios, perturbações na copa das árvores e processos de degradação florestal que podem preceder o desmatamento em larga escala. Essas capacidades são especialmente relevantes na Amazônia, onde as mudanças ambientais frequentemente ocorrem de forma gradual e em paisagens heterogêneas.

Outra descoberta importante diz respeito à crescente integração de conjuntos de dados multimodais com estruturas avançadas de GeoIA. Estudos que empregam arquiteturas de aprendizado profundo juntamente com plataformas de processamento geoespacial baseadas em nuvem relataram melhorias na automação, escalabilidade e desempenho preditivo. Esses desenvolvimentos indicam uma transição de abordagens de mapeamento convencionais para sistemas inteligentes de monitoramento ambiental capazes de suportar análises quase em tempo real e processos de tomada de decisão em larga escala.

Apesar desses avanços, desafios importantes permanecem. Questões relacionadas à interoperabilidade de sensores, disponibilidade de dados, requisitos computacionais, padronização metodológica e reprodutibilidade de modelos continuam a limitar uma implementação operacional mais ampla. Além disso, os altos custos associados à aquisição de dados LiDAR e a distribuição espacial desigual dos conjuntos de dados de treinamento podem restringir a transferibilidade de modelos GeoAI entre diferentes regiões da Amazônia. Superar essas limitações será essencial para maximizar a eficácia a longo prazo de sistemas integrados de monitoramento para a conservação da biodiversidade e a governança ambiental.

4.3 Aplicações em biodiversidade e monitoramento faunístico

Os estudos analisados evidenciam um crescimento consistente de aplicações em biodiversidade baseadas em visão computacional, armadilhas fotográficas automatizadas e classificação automatizada de espécies. Modelos de aprendizado profundo demonstraram elevada acurácia na identificação de fauna em imagens provenientes de camera traps, reduzindo significativamente o esforço de triagem manual e ampliando a escala operacional do monitoramento ecológico (Norouzzadeh et al. 2018; Willi et al. 2018).

Em particular, redes neurais convolucionais têm apresentado desempenho robusto em tarefas de reconhecimento visual, sobretudo para mamíferos de médio e grande porte. No entanto, esse desempenho não é homogêneo entre grupos taxonômicos, revelando um viés estrutural associado à disponibilidade de dados e à representatividade das classes. Espécies raras, crípticas ou subamostradas tendem a apresentar menor precisão preditiva, evidenciando limitações taxonômicas importantes nos modelos atuais.

Apesar dos avanços em eficiência e escalabilidade, persistem restrições relevantes relacionadas à dependência de grandes bases de dados rotuladas, sensibilidade à qualidade das imagens e dificuldades de generalização entre diferentes contextos ecológicos. Variações ambientais, como densidade da vegetação, condições de iluminação e sazonalidade, afetam diretamente o desempenho dos modelos, reduzindo sua transferibilidade espacial.

Aplicações voltadas à avifauna e outros grupos taxonômicos também reforçam o potencial da automação para apoio à conservação e ao monitoramento populacional (Kim et al. 2022; Fergus et al. 2024). Entretanto, revisões recentes indicam que o avanço da GeoAI na biodiversidade ainda é fortemente concentrado em tarefas de classificação e reconhecimento de imagens, enquanto abordagens mais integradas permanecem incipientes. Destaca-se, nesse sentido, a baixa incorporação de bioacústica, bem como a limitada exploração de insetos, organismos de difícil detecção e interações ecológicas complexas.

Paralelamente, observa-se uma tendência crescente de integração entre observação da Terra e dados biológicos de alta resolução, potencializando análises ecológicas em múltiplas escalas. Essa convergência entre sensoriamento remoto, bases ecológicas massivas e inteligência artificial tem ampliado aplicações em modelagem de habitats, identificação de áreas prioritárias para conservação e avaliação de impactos ambientais sobre a biodiversidade (Turner et al. 2003; Pettorelli et al. 2014; Skidmore et al. 2015; Bush et al. 2017).

Esse avanço é particularmente relevante na Amazônia, um dos sistemas de maior complexidade e diversidade biológica do planeta (Garda et al. 2010; Lovejoy 2017; Guayasamin et al. 2024), onde a GeoAI se consolida como ferramenta estratégica para monitoramento em larga escala e em regiões de difícil acesso. Ainda assim, sua aplicação prática permanece mais concentrada em detecção e classificação do que em análises ecológicas integradas.

Nesse contexto, os estudos analisados indicam que a GeoAI também pode contribuir para a identificação de padrões espaciais de distribuição da fauna, fragmentação de habitats e respostas ecológicas a mudanças ambientais. Contudo, abordagens relacionadas à conectividade ecológica, redes tróficas e dinâmica populacional ainda são pouco exploradas, configurando uma lacuna metodológica relevante.

Os principais desafios identificados incluem baixa disponibilidade de dados rotulados, reduzida representatividade taxonômica, desbalanceamento amostral e heterogeneidade ambiental entre regiões. Esses fatores comprometem a generalização dos modelos, especialmente em cenários com espécies raras ou ambientes subamostrados. Além disso, observa-se limitação na reprodutibilidade computacional e ausência de padronização entre bases ecológicas utilizadas para treinamento e validação.

Além disso, as aplicações emergentes da GeoIA vão além da identificação automatizada de espécies e apresentam um potencial crescente para a ecologia do movimento e avaliações da biodiversidade em escala de paisagem. A integração da telemetria GPS, produtos de sensoriamento remoto e algoritmos de aprendizado de máquina permite a análise de padrões de movimento animal, seleção de habitat, processos de dispersão e conectividade ecológica em paisagens fragmentadas. Essas abordagens podem contribuir para a identificação de corredores ecológicos, avaliação da permeabilidade do habitat e avaliação da dinâmica metapopulacional, apoiando o planejamento da conservação em ambientes altamente heterogêneos, como a Amazônia. Ademais, o monitoramento bioacústico combinado com algoritmos de aprendizado profundo emergiu como uma ferramenta promissora para a detecção automatizada de espécies e avaliação da biodiversidade em áreas remotas, embora sua aplicação ainda seja sub-representada nos estudos revisados. Expandir a integração da GeoIA com telemetria, bioacústica e análises de conectividade representa uma importante oportunidade para o avanço do monitoramento da biodiversidade em escala ecossistêmica e das estratégias de conservação.

De forma geral, os resultados indicam que a integração entre GeoAI, sensores ambientais e bases ecológicas em larga escala tem potencial para transformar o monitoramento da biodiversidade em sistemas quase em tempo real. Entretanto, esse avanço depende do fortalecimento de bases de dados mais representativas, da ampliação de abordagens multimodais (incluindo bioacústica e outros sensores) e do desenvolvimento de modelos mais generalizáveis e ecologicamente interpretáveis.

4.4 Implicações ecológicas e conservação da Amazônia

Os resultados desta revisão evidenciaram forte concentração de aplicações voltadas ao monitoramento do desmatamento e da degradação florestal na Amazônia. Essa predominância pode ser explicada pela relevância global do bioma amazônico para a estabilidade climática,

conservação da biodiversidade e manutenção dos ciclos biogeoquímicos (Lovejoy, 2017; Malhi et al., 2008).

Diversos estudos demonstraram que a degradação florestal representa componente crítico das emissões de carbono na Amazônia e frequentemente permanece subestimada em programas convencionais de monitoramento ambiental (Assis et al., 2020; Lapola et al., 2023; Mataveli et al., 2025). Além disso, pesquisas anteriores já alertavam que processos associados à expansão agropecuária, queimadas e mudanças climáticas vêm intensificando a vulnerabilidade ecológica da região amazônica (Morton et al., 2006; Fearnside, 2017; Nobre et al., 2016).

As análises também demonstraram que o monitoramento automatizado pode contribuir significativamente para a identificação precoce de alterações ambientais, subsidiando políticas públicas de conservação, manejo florestal sustentável e planejamento territorial. Estudos utilizando modelos preditivos apresentaram capacidade relevante para prever padrões espaciais de desmatamento e degradação ambiental em diferentes regiões amazônicas (Ball et al., 2022). Tais aplicações podem fortalecer sistemas de fiscalização ambiental e auxiliar órgãos governamentais na priorização de áreas críticas para intervenção e conservação.

Além disso, o uso de sensoriamento remoto associado à inteligência artificial pode ampliar significativamente a capacidade operacional de monitoramento ambiental em áreas extensas e de difícil acesso, permitindo análises mais rápidas, contínuas e espacialmente detalhadas da dinâmica florestal amazônica (Turner et al., 2003; Hansen et al., 2013). Essa capacidade é particularmente relevante para o acompanhamento de áreas protegidas, concessões florestais, processos de restauração ecológica e monitoramento de impactos associados à exploração seletiva e aos incêndios florestais.

Os resultados desta revisão também reforçam que a ampliação da capacidade de monitoramento ambiental possui implicações diretas para estratégias de conservação e governança territorial. A disponibilidade de informações espaciais de alta resolução favorece ações de fiscalização ambiental, identificação de áreas prioritárias para conservação, monitoramento da efetividade de unidades de conservação e planejamento territorial baseado em evidências científicas. Adicionalmente, estimativas mais precisas de biomassa, carbono e degradação florestal podem contribuir para programas internacionais de mitigação climática, incluindo iniciativas de Redução de Emissões por Desmatamento e Degradação Florestal (REDD+), fortalecendo mecanismos de monitoramento, reporte e verificação ambiental.

Nesse contexto, a GeoAI apresenta potencial estratégico não apenas para monitoramento reativo, mas também para a construção de sistemas preditivos capazes de antecipar áreas sob maior risco de degradação ambiental. Essa capacidade torna-se particularmente relevante diante do avanço das mudanças climáticas e da crescente pressão antrópica sobre os ecossistemas amazônicos. Considerando o crescente protagonismo da Amazônia nas agendas globais de clima e biodiversidade, especialmente no contexto das discussões associadas à COP30 e aos compromissos internacionais de conservação, o fortalecimento de sistemas baseados em GeoAI poderá desempenhar papel fundamental no suporte à tomada de decisão, à governança ambiental e à implementação de estratégias de desenvolvimento sustentável na região.

4.5 Limitações metodológicas e desafios futuros

Apesar dos avanços observados, a revisão também identificou limitações metodológicas importantes nos estudos analisados. Parte significativa das pesquisas apresentou ausência de validação externa independente, reduzindo a capacidade de generalização dos modelos desenvolvidos. Além disso, observou-se elevada heterogeneidade entre métricas de desempenho, escalas espaciais e conjuntos de treinamento utilizados, dificultando comparações diretas entre aplicações distintas. Revisões recentes indicam que a

ausência de padronização metodológica ainda representa um dos principais desafios para consolidação da GeoAI aplicada ao monitoramento ambiental (Tuia et al. 2024; Lei et al. 2026).

Outra limitação recorrente relaciona-se à disponibilidade de dados rotulados e ao desbalanceamento amostral, especialmente em aplicações envolvendo biodiversidade e espécies raras. Em muitos casos, modelos treinados em conjuntos de dados limitados apresentaram redução de desempenho em cenários ecológicos mais heterogêneos ou pouco representados nos bancos de treinamento (Besson et al. 2022).

Os estudos analisados também demonstraram forte predominância de aplicações concentradas em áreas mais monitoradas da Amazônia brasileira, enquanto regiões periféricas e áreas transfronteiriças permaneceram relativamente subamostradas. Essa desigualdade espacial pode introduzir vieses importantes nos modelos preditivos, comprometendo sua capacidade de extrapolação para diferentes contextos ambientais e fitogeográficos.

Outro desafio relevante refere-se à interpretabilidade dos modelos de inteligência artificial. Embora arquiteturas profundas apresentem elevada capacidade preditiva, muitos modelos ainda operam com baixa transparência analítica, dificultando a compreensão ecológica dos processos modelados. Nesse contexto, abordagens baseadas em knowledge-guided machine learning vêm sendo apontadas como alternativas promissoras para integração entre conhecimento ecológico e aprendizado computacional (Karpatne et al. 2024).

Também foram identificadas limitações relacionadas à dependência de infraestrutura computacional avançada e à necessidade de grandes volumes de dados para treinamento dos modelos. Em muitos contextos amazônicos, dificuldades logísticas, restrições de conectividade e baixa disponibilidade de bases ambientais padronizadas ainda representam obstáculos importantes para implementação operacional de sistemas automatizados de monitoramento ambiental.

Além disso, aplicações relacionadas ao monitoramento faunístico, conectividade ecológica e interações ecológicas complexas ainda permanecem menos consolidadas quando comparadas às aplicações voltadas ao desmatamento e à estrutura florestal. Essa diferença evidencia a necessidade de ampliação de bases ecológicas integradas, maior representatividade taxonômica e desenvolvimento de protocolos metodológicos mais padronizados para estudos de biodiversidade amazônica.

De maneira geral, esta revisão evidencia que a GeoAI representa ferramenta estratégica para o monitoramento da biodiversidade amazônica e para compreensão das dinâmicas ambientais em larga escala. Entretanto, avanços futuros dependerão da ampliação de bases de dados ecológicos, maior padronização metodológica, validações independentes mais robustas e integração entre conhecimento ecológico, sensoriamento remoto e desenvolvimento computacional (Reichstein et al. 2019; Tuia et al. 2024).

5. CONSIDERAÇÕES FINAIS

A presente revisão sistemática evidenciou que a integração entre GeoAI, sensoriamento remoto e inteligência artificial vem ampliando significativamente a capacidade de monitoramento ambiental da Amazônia, especialmente em aplicações relacionadas ao desmatamento, degradação florestal, biomassa, estrutura da vegetação e biodiversidade.

Os resultados demonstraram predominância de abordagens baseadas em aprendizado profundo, particularmente redes neurais convolucionais (CNNs), além de crescimento expressivo da integração multimodal entre sensores ópticos, SAR, LiDAR e drones/UAS. Estudos recentes indicaram que essas abordagens apresentam elevado desempenho preditivo e maior capacidade de detecção de padrões ecológicos complexos em ecossistemas tropicais.

Apesar dos avanços observados, a revisão também identificou limitações importantes, incluindo heterogeneidade metodológica, baixa padronização das métricas de validação, reduzida disponibilidade de dados rotulados e menor representatividade de aplicações voltadas ao monitoramento faunístico, conectividade ecológica e regiões amazônicas subamostradas.

Conclui-se que a GeoAI possui elevado potencial estratégico para fortalecimento do monitoramento ambiental amazônico, contribuindo para aplicações em conservação da biodiversidade, manejo florestal sustentável, planejamento territorial e apoio à formulação de políticas públicas ambientais. Entretanto, avanços futuros dependem da ampliação de bases de dados amazônicas, maior transparência metodológica e integração entre diferentes fontes de dados ambientais e ecológicos.

6. REFERÊNCIAS

- ASSIS, T.; AGUIAR, A. P. D.; VON RANDOW, C.; GOMES, D.; KURY, J.; OMETTO, J. P.; NOBRE, C. **CO₂ emissions from forest degradation in Brazilian Amazon.** *Environmental Research Letters*, v. 15, 2020. DOI: 10.1088/1748-9326/ab9cfc.
- ASNER, G. P.; POWELL, G. V.; MASCARO, J.; KNAPP, D. E.; CLARK, J. K.; JACOBSON, J.; KENNEDY-BOWDOIN, T.; BALAJI, A.; PAEZ-ACOSTA, G.; VICTORIA, E.; SECADA, L.; VALQUI, M.; HUGHES, R. F. **High-resolution forest carbon stocks and emissions in the Amazon.** *Proceedings of the National Academy of Sciences*, v. 107, n. 38, p. 16738–16742, 2010. DOI: 10.1073/pnas.1004875107.
- BALL, J. G. C.; PETROVA, K.; COOMES, D. A.; FLAXMAN, S. **Using deep convolutional neural networks to forecast spatial patterns of Amazonian deforestation.** *Methods in Ecology and Evolution*, v. 13, n. 11, p. 2622–2634, 2022. DOI: 10.1111/2041-210X.13953.
- BESSON, M.; ALISON, J.; BJERGE, K.; GOROCHOWSKI, T. E.; HØYE, T. T.; JUCKER, T.; MANN, H. M. R.; CLEMENTS, C. F. **Towards the fully automated monitoring of ecological communities.** *Ecology Letters*, v. 25, n. 12, p. 2753–2775, 2022. DOI: 10.1111/ele.14123.
- BUSH, A.; SOLLMANN, R.; WILTING, A.; BOHMANN, K.; COLE, B.; BALZTER, H.; MARTIUS, C.; ZLINSZKY, A.; CALVIGNAC-SPENCER, S.; COBBOLD, C.; DAWSON, T.; EMERSON, B.; FERRIER, S.; GILBERT, M.; HEROLD, M.; JONES, L.; LEENDERTZ, F.; MATTHEWS, L.; MILLINGTON, J.; YU, D. **Connecting Earth observation to high-throughput biodiversity data.** *Nature Ecology & Evolution*, v. 1, p. 0176, 2017. DOI: 10.1038/s41559-017-0176.
- DAL MOLIN, R. J.; THIRION-LEFEVRE, L.; GUINVARC'H, R.; RIZZOLI, P. **Rainforest monitoring using deep learning and short time series of Sentinel-1 IW data.** *Remote Sensing*, v. 18, n. 4, p. 598, 2026. DOI: 10.3390/rs18040598.
- DALAGNOL, R.; WAGNER, F. H.; EMILIO, T.; STREHER, A. S.; GALVÃO, L. S.; OMETTO, J. P. H. B.; ARAGÃO, L. E. O. C. **Canopy palm cover across the Brazilian Amazon forests mapped with airborne LiDAR data and deep learning.** *Remote Sensing in Ecology and Conservation*, v. 8, p. 601–614, 2022. DOI: 10.1002/rse2.264.

FEARNSIDE, P. M. **Deforestation of the Brazilian Amazon.** *Oxford Research Encyclopedia of Environmental Science*, 2017. DOI: 10.1093/acrefore/9780199389414.013.102.

FERGUS, P.; CHALMERS, C.; LONGMORE, S.; WICH, S. **Harnessing artificial intelligence for wildlife conservation.** *Conservation*, v. 4, p. 685–702, 2024. DOI: 10.3390/conservation4040041.

GARDA, A. A.; SILVA, J. M. C.; BAIÃO, P. C. **Biodiversity conservation and sustainable development in the Amazon.** *Systematics and Biodiversity*, v. 8, n. 2, p. 169–175, 2010. DOI: 10.1080/14772000.2010.484435.

GÓMEZ-CHOVA, L.; TUIA, D.; MOSER, G.; CAMPS-VALLS, G. **Multimodal classification of remote sensing images: a review and future directions.** *Proceedings of the IEEE*, v. 103, n. 9, p. 1560–1584, 2015. DOI: 10.1109/JPROC.2015.2449668.

GUAYASAMIN, J. M.; RIBAS, C. C.; CARNAVAL, A. C.; CARRILLO, J. D.; HOORN, C.; LOHMANN, L. G.; RIFF, D.; ULLOA ULLOA, C.; ALBERT, J. S. **Evolution of Amazonian biodiversity: a review.** *Acta Amazonica*, v. 54, 2024. DOI: 10.1590/1809-4392202103601.

HANSEN, M. C.; POTAPOV, P. V.; MOORE, R.; HANCHER, M.; TURUBANOVA, A. S.; TYUKAVINA, A.; THAU, D.; STEHMAN, S. V.; GOETZ, S. J.; LOVELAND, T. R.; KOMMAREDDY, A.; EGOROV, A.; CHINI, L.; JUSTICE, C. O.; TOWNSHEND, J. R. **High-resolution global maps of 21st-century forest cover change.** *Science*, v. 342, n. 6160, p. 850–853, 2013. DOI: 10.1126/science.1244693.

KARPATNE, A.; JIA, X.; KUMAR, V. **Knowledge-guided machine learning: current trends and future prospects.** arXiv preprint, 2024. DOI: 10.48550/arXiv.2403.15989.

KHELIFI, L.; MIGNOTTE, M. **Deep learning for change detection in remote sensing images: comprehensive review and meta-analysis.** *IEEE Access*, v. 8, p. 126385–126400, 2020. DOI: 10.1109/ACCESS.2020.3008036.

KIM, J. I.; BAEK, J. W.; KIM, C. B. **Image classification of Amazon parrots by deep learning: a potentially useful tool for wildlife conservation.** *Biology*, v. 11, n. 9, p. 1303, 2022. DOI: 10.3390/biology11091303.

LAPOLA, D. M.; PINHO, P.; BARLOW, J.; ARAGÃO, L. E. O. C.; BERENGUER, E.; CARMENTA, R.; LIDDY, H. M.; SEIXAS, H.; SILVA, C. V. J.; SILVA-JUNIOR, C. H. L.; ALENCAR, A. A. C.; ANDERSON, L. O.; ARMENTERAS, D.; BROVKIN, V.; CALDERS, K.; CHAMBERS, J.; CHINI, L.; COSTA, M. H.; FARIA, B. L.; FEARNSIDE, P. M.; FERREIRA, J.; GATTI, L.; GUTIERREZ-VELEZ, V. H.; HAN, Z.; HIBBARD, K.; KOVEN, C.; LAWRENCE, P.; PONGRATZ, J.; PORTELA, B. T. T.; ROUNSEVELL, M.; RUANE, A. C.; SCHALDACH, R.; SILVA, S. S.; VON RANDOW, C.; WALKER, W. S. **The drivers and impacts of Amazon forest degradation.** *Science*, v. 379, n. 6630, p. eabp8622, 2023. DOI: 10.1126/science.abp8622.

LEI, T.; ZHANG, S.; LIN, S.; LIU, T.; LV, Z.; GAO, T.; GONG, M.; NANDI, A. **Remote sensing image change detection using deep learning techniques: a comprehensive survey.** *Artificial Intelligence Review*, v. 59, 2026. DOI: 10.1007/s10462-026-11501-0.

LOPES, A.; STARK, S.; SMITH, M.; ALMEIDA, D.; SHAO, G.; SATO, L.; RINCON, N.; MARTINS, G.; GONÇALVES, N.; OMETTO, J.; GRAÇA, P. M. A.; ARAGÃO, L. **Fire in a Central Amazon forest: lingering top canopy loss and initial understory regrowth revealed by repeated LiDAR.** *Forest Ecology and Management*, 2025. DOI: 10.1016/j.foreco.2025.123332.

LOVEJOY, T. E. **The Amazon region.** *Science Advances*, v. 3, p. eaar3677, 2017. DOI: 10.1126/sciadv.aar3677.

MALHI, Y.; ROBERTS, J. T.; BETTS, R. A.; KILLEEN, T. J.; LI, W.; NOBRE, C. A. **Climate change, deforestation, and the fate of the Amazon.** *Science*, v. 319, n. 5860, p. 169–172, 2008. DOI: 10.1126/science.1146961.

MATAVELI, G.; MAURE, L. A.; SANCHEZ, A.; DUTRA, D. J.; OLIVEIRA, G.; JONES, M. W.; AMARAL, C.; ARTAXO, P.; ARAGÃO, L. E. O. C. **Forest degradation is undermining progress on deforestation in the Amazon.** *Global Change Biology*, v. 31, n. 4, p. e70209, 2025. DOI: 10.1111/gcb.70209.

MORTON, D. C.; DEFRIES, R. S.; SHIMABUKURO, Y. E.; ANDERSON, L. O.; ARAI, E.; BOM ESPIRITO-SANTO, F.; FREITAS, R.; MORISETTE, J. **Cropland expansion changes deforestation dynamics in the southern Brazilian Amazon.** *Proceedings of the National Academy of Sciences*, v. 103, n. 39, p. 14637–14641, 2006. DOI: 10.1073/pnas.0606377103.

NOBRE, C. A.; SAMPAIO, G.; BORMA, L. S.; CASTILLA-RUBIO, J. C.; SILVA, J. S.; CARDOSO, M. **Land-use and climate change risks in the Amazon and the need of a novel sustainable development paradigm.** *Proceedings of the National Academy of Sciences*, v. 113, n. 39, p. 10759–10768, 2016. DOI: 10.1073/pnas.1605516113.

NOROUZZADEH, M. S.; NGUYEN, A.; KOSMALA, M.; SWANSON, A.; PALMER, M. S.; PACKER, C.; CLUNE, J. **Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning.** *Proceedings of the National Academy of Sciences*, v. 115, n. 25, p. E5716–E5725, 2018. DOI: 10.1073/pnas.1719367115.

NOROUZZADEH, M. S.; SWEENEY, S.; VERCAUTEREN, K.; SNOW, N.; HALSETH, J.; SALVO, P.; LEWIS, J.; WHITE, M.; TETON, B.; BOUGHTON, R.; WIGHT, B.; NEWKIRK, E.; ODELL, E.; BROOK, R.; MOELLER, A.; MANDEVILLE, E.; CLUNE, J.; MILLER, R.; SCHLICHTING, P. **Machine learning to classify animal species in camera trap images: applications in ecology.** *Methods in Ecology and Evolution*, v. 10, p. 585–590, 2019. DOI: 10.1111/2041-210X.13120.

PAGE, M. J.; MCKENZIE, J. E.; BOSSUYT, P. M.; et al. **The PRISMA 2020 statement: an updated guideline for reporting systematic reviews.** *BMJ*, v. 372, p. n71, 2021. DOI: 10.1136/bmj.n71.

PETTORELLI, N.; et al. **Satellite remote sensing for applied ecologists.** *Trends in Ecology & Evolution*, v. 29, p. 397–405, 2014. DOI: 10.1016/j.tree.2014.05.005.

REICHSTEIN, M.; CAMPS-VALLS, G.; STEVENS, B.; JUNG, M.; DENZLER, J.; CARVALHAIS, N.; PRABHAT. **Deep learning and process understanding for data-driven Earth system science.** *Nature*, v. 566, p. 195–204, 2019. DOI: 10.1038/s41586-019-0912-1.

SKIDMORE, A. K.; PETTORELLI, N.; COOPS, N. C.; GELLER, G. N.; HANSEN, M.; LUCAS, R.; MÜCHER, C. A.; O’CONNOR, B.; PAGANINI, M.; PEREIRA, H. M.; SCHAEPMAN, M. E.; TURNER, W.; WANG, T.; WEGMANN, M. **Environmental science: agree on biodiversity metrics to track from space.** *Nature*, v. 523, n. 7561, p. 403–405, 2015. DOI: 10.1038/523403a.

TUIA, D.; SCHINDLER, K.; DEMIR, B.; ZHU, X.; KOCHUPILLAI, M.; DŽEROSKI, S.; VAN RIJN, J.; HOOS, H.; DEL FRATE, F.; DATCU, M.; MARKL, V.; SAUX, B.; SCHNEIDER, R.; CAMPS-VALLS, G. **Artificial intelligence to advance Earth observation: a review of models, recent trends, and pathways forward.** *IEEE Geoscience and Remote Sensing Magazine*, p. 2–25, 2024. DOI: 10.1109/MGRS.2024.3425961.

TURNER, W.; SPECTOR, S.; GARDINER, N.; FLADELAND, M.; STERLING, E.; STEINER, M. **Remote sensing for biodiversity science and conservation.** *Trends in Ecology & Evolution*, v. 18, n. 6, p. 306–314, 2003. DOI: 10.1016/S0169-5347(03)00070-3.

VALLE, D.; HANEDA, L.; BRACK, I. V.; OMETTO, J.; CSILLIK, O.; LONGO, M.; KELLER, M.; ALMEIDA, D. **Characterizing the vertical structure of forests in the Brazilian Amazon.** *Communications Earth & Environment*, v. 7, n. 1, p. 25, 2026. DOI: 10.1038/s43247-025-02976-w.

VERAS, H. P. F.; FERREIRA, M. P.; CUNHA NETO, E. M.; FIGUEIREDO, E. O.; DALLA CORTE, A. P.; SANQUETTA, C. R. **Fusing multi-season UAS images with convolutional neural networks to map tree species in Amazonian forests.** *Ecological Informatics*, v. 71, p. 101815, 2022. DOI: 10.1016/j.ecoinf.2022.101815.

WILLI, M.; PITMAN, R.; CARDOSO, A.; LOCKE, C.; SWANSON, A.; BOYER, A.; VELDTHUIS, M.; FORTSON, L. **Identifying animal species in camera trap images using deep learning and citizen science.** *Methods in Ecology and Evolution*, v. 10, p. 80–91, 2018. DOI: 10.1111/2041-210X.13099.

ZHU, X. X.; et al. **Deep learning in remote sensing: a comprehensive review and list of resources.** *IEEE Geoscience and Remote Sensing Magazine*, v. 5, p. 8–36, 2017. DOI: 10.1109/MGRS.2017.2762307.

NOTAS

CONTRIBUIÇÃO DE AUTORIA

A autora foi responsável por todas as etapas da pesquisa.
Concepção e elaboração do manuscrito: E. R. A. dos Reis
Coleta de dados: E. R. A. dos Reis
Análise de dados: E. R. A. dos Reis
Discussão dos resultados: E. R. A. dos Reis
Revisão e aprovação: E. R. A. dos Reis

PREPRINTS

O manuscrito não é um preprint.

CONFLITO DE INTERESSES

Os autores declaram não haver conflito de interesses.

DISPONIBILIDADE DE DADOS DE PESQUISA E OUTROS MATERIAIS

Os dados foram publicados no próprio artigo. Todo o conjunto de dados que dá suporte aos resultados deste estudo está incluído no corpo do artigo.

ANUÊNCIA DE AVALIAÇÃO ABERTA

Não.



O conteúdo deste trabalho pode ser usado sob os termos da licença Creative Commons Attribution 4.0. Qualquer outra distribuição deste trabalho deve manter a atribuição ao(s) autor(es) e o título do trabalho, citação da revista e DOI.