



Deep Learning: uma Revisão Sistemática Integrativa de Suas Aplicações em Mapeamento Utilizando Imagens de RPA

Deep Learning: an Integrative Systematic Review of Its Applications in Mapping Using UAV Imagery

Elmo Bispo de Oliveira¹, Vivian de Oliveira Fernandes² e Mauro José Alixandrini Júnior³

¹ Universidade Federal da Bahia, Salvador, Brasil. elmo.bispo@ufba.br.

ORCID: <https://orcid.org/0009-0005-5797-2219>

² Universidade Federal da Bahia, Salvador, Brasil. vivian.fernandes@ufba.br.

ORCID: <https://orcid.org/0000-0002-2851-9141>

³ Universidade Federal da Bahia, Salvador, Brasil. alixandrini@ufba.br.

ORCID: <https://orcid.org/0000-0002-5376-7171>

Recebido: 06.2025 | Aceito: 10.2025

Resumo: O avanço das técnicas de aprendizado profundo (*Deep Learning* - DL) tem ampliado o uso de Aeronaves Remotamente Pilotadas (RPAs) no mapeamento cartográfico e no sensoriamento remoto, impulsionando a automação e a precisão dos produtos geoespaciais. Diante do crescimento expressivo dessas aplicações, este artigo tem como objetivo sistematizar e analisar criticamente as pesquisas que integram DL e RPAs no contexto do mapeamento, considerando as principais arquiteturas de redes neurais, sensores empregados e áreas de aplicação. Foi conduzida uma revisão sistemática integrativa nas bases *Web of Science*, *Scopus* e *ScienceDirect*, abrangendo o período de 2020 a 2025. A triagem resultou em 22 artigos incluídos, classificados em cinco categorias temáticas: agricultura, detecção de objetos, inspeções, incêndios e LiDAR. Os resultados evidenciam o predomínio das arquiteturas YOLO e U-Net, a crescente adoção de dados multispectrais e térmicos e a carência de padronização metodológica nos procedimentos de treinamento e validação. A análise integrativa permitiu identificar tendências, lacunas e desafios éticos e técnicos na aplicação de DL com RPAs para o mapeamento cartográfico. A pesquisa contribui para a consolidação do conhecimento técnico-científico sobre o tema e reforça a importância de protocolos e práticas padronizadas no desenvolvimento de produtos cartográficos baseados em inteligência artificial.

Palavras-chave: Visão Computacional. Redes Neurais Convolucionais. YOLO. U-Net. Atualização Cartográfica.

Abstract: The advances in Deep Learning (DL) techniques have expanded the use of Unmanned Aerial Vehicles (UAVs) for cartographic mapping and remote sensing, enhancing automation and the accuracy of geospatial products. Given the rapid growth of such applications, this article aims to systematize and critically analyze research integrating DL and UAV imagery in the mapping context, focusing on the main neural network architectures, sensors, and application domains. An integrative systematic review was conducted using the *Web of Science*, *Scopus*, and *ScienceDirect* databases, covering the period from 2020 to 2025. The screening process resulted in 22 selected studies, grouped into five thematic categories: agriculture, object detection, inspections, wildfires, and LiDAR. The findings highlight the predominance of YOLO and U-Net architectures, the increasing use of multispectral and thermal data, and the lack of methodological standardization in training and validation processes. The integrative analysis revealed trends, gaps, and ethical and technical challenges in applying DL with UAV imagery for mapping purposes. This research contributes to consolidating technical and scientific knowledge in this field and reinforces the need for standardized protocols and practices in the development of AI-based cartographic products.

Keywords: Computer Vision. Convolutional Neural Networks. YOLO. U-Net. Cartographic Updating.

1 INTRODUÇÃO

Nas últimas décadas, o avanço das técnicas de aprendizado profundo (*Deep Learning* - DL) tem impulsionado transformações significativas no campo do sensoriamento remoto e do mapeamento cartográfico. A capacidade dessas redes neurais em extrair automaticamente padrões complexos e aprender representações de alto nível a partir de grandes volumes de dados visuais vem ampliando as possibilidades de

automação e análise em diferentes áreas da geoinformação (Yigitcanlar et al., 2024a). Essa evolução tecnológica tem sido acompanhada pela maior disponibilidade de sensores ópticos, multiespectrais e LiDAR embarcados em Aeronaves Remotamente Pilotadas (RPAs), que fornecem dados de alta resolução espacial e temporal a custos cada vez mais acessíveis (Prince, 2023; Zhang et al., 2024).

O uso combinado de DL e RPAs tem se destacado como uma das frentes mais promissoras para mapeamento automático, detecção de feições e atualização cartográfica. A aplicação dessas técnicas permite reconhecer alvos, classificar objetos e segmentar superfícies com elevada precisão e repetibilidade, superando limitações inerentes à interpretação visual tradicional. Além disso, a incorporação de fluxos de trabalho baseados em redes convolucionais (CNNs) - como YOLO, U-Net, DeepLab e Mask R-CNN - vem ampliando o escopo de análise e a eficiência na geração de produtos cartográficos derivados de imagens aéreas (Aszkowski et al., 2023; Park et al., 2024).

Entretanto, apesar da expressiva expansão de estudos que integram DL e RPAs no sensoriamento remoto, a literatura ainda apresenta grande heterogeneidade metodológica e temática. As diferenças entre arquiteturas de redes, configurações de sensores, resoluções espaciais e métricas de avaliação tornam difícil a comparação de resultados e a consolidação de boas práticas na área. Ademais, observa-se a ausência de sistematizações críticas recentes que abordem simultaneamente os aspectos técnicos, metodológicos e cartográficos dessas aplicações, sobretudo no contexto de atualização de bases geoespaciais e representação do espaço urbano e rural. Essa lacuna dificulta a avaliação da maturidade científica do campo e a identificação de tendências consistentes de pesquisa.

Diante desse panorama, este estudo busca responder à seguinte questão de pesquisa: quais são as principais características metodológicas, tecnológicas e temáticas que definem o uso de aprendizado profundo em aplicações cartográficas baseadas em imagens obtidas por RPAs entre 2020 e 2025?

Para responder a essa questão, foi desenvolvida uma revisão sistemática da literatura nas bases *Web of Science*, *Scopus* e *ScienceDirect*, a fim de garantir transparência, reproduzibilidade e padronização no processo de busca, triagem e análise dos estudos incluídos. O recorte temporal de 2020 a 2025 foi adotado com o propósito de abranger o período mais recente de consolidação das técnicas de DL aplicadas ao mapeamento, contemplando os avanços decorrentes da popularização das RPAs e da disponibilidade de ferramentas de código aberto para processamento geoespacial.

A contribuição desta revisão reside em articular, sob uma perspectiva crítica e integradora, os eixos tecnológico, cartográfico e metodológico do uso de DL em RPAs, analisando os tipos de sensores embarcados, as arquiteturas de redes neurais mais empregadas e as áreas temáticas predominantes. Ao realizar essa síntese, pretende-se contribuir para a compreensão das tendências recentes, das lacunas de padronização e dos desafios éticos e operacionais que permeiam a aplicação de inteligência artificial no mapeamento geoespacial. O artigo, portanto, busca oferecer uma referência consolidada para pesquisadores e profissionais da cartografia, promovendo avanços na integração entre aprendizado profundo, sensoriamento remoto e ciência da informação geográfica.

2 ABORDAGEM METODOLÓGICA

A revisão sistemática integrativa foi estruturada contemplando três etapas principais: planejamento da revisão, execução da busca e sistematização dos dados, e análise quantitativa e interpretativa dos resultados. A revisão integrativa foi escolhida por permitir a síntese de diferentes tipos de evidências - empíricas e teóricas – de forma crítica e interpretativa conforme Snyder (2019), integrando resultados de pesquisas recentes sobre o uso de DL em RPAs sob múltiplas perspectivas técnicas e cartográficas. Essa estrutura orientou a seleção criteriosa das fontes, a aplicação dos filtros de inclusão e exclusão, e a organização dos artigos em categorias temáticas, garantindo transparência e reproduzibilidade no processo de revisão. O processo metodológico passou pelas seguintes etapas:

- (a) quais os tipos de sensores têm sido embarcados em RPAs para fins cartográficos;
- (b) quais softwares e plataformas de código aberto têm sido empregados no processamento dos dados;
- (c) quais áreas de aplicação integram RPAs e algoritmos de DL no contexto da produção

cartográfica.

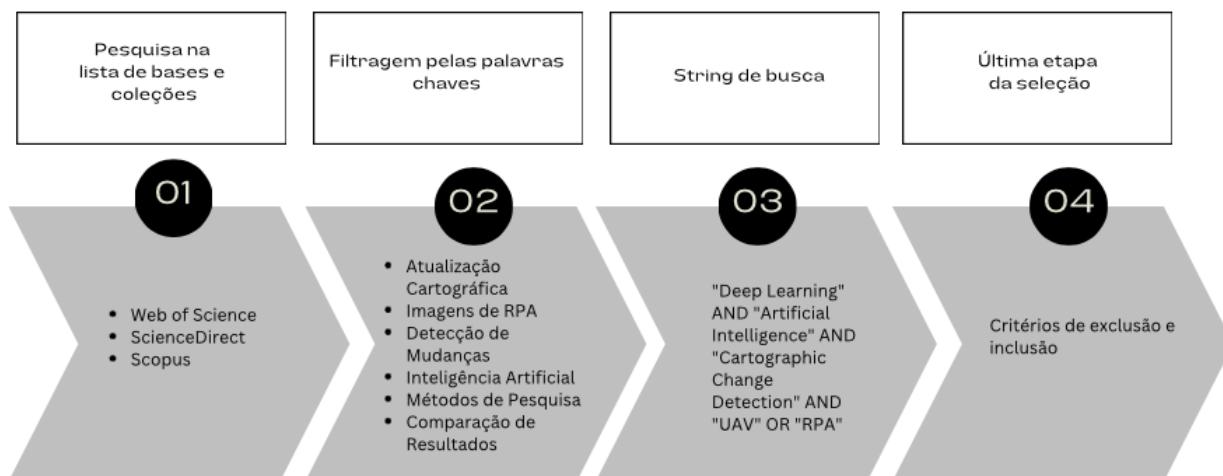
2.1 Planejamento da revisão

O planejamento da revisão foi estruturado de forma a conhecer as diversas referências, objetivando destacar: a) busca de artigos no universo geral de observação; b) definição das cinco categorias; c) principais bases de busca; d) categorização temática confirmando a pertinência dos artigos em cada grupo. Sendo assim, o propósito da revisão sistemática foi verificar as inovações e aplicações do DL a partir de imagens de RPA. O intervalo de 2020 a 2025 foi definido por representar o período de consolidação das aplicações de aprendizado profundo em dados de RPA, marcando uma fase de expressiva evolução nas arquiteturas de redes neurais e na disponibilidade de plataformas de código aberto voltadas ao mapeamento geoespacial.

Dessa forma, o método de busca foi estruturado seguindo as seguintes perguntas: (i) a partir do tema de pesquisa pré-definido, quais os objetivos gerais e específicos que devem ser priorizados? (ii) a partir do resultado encontrado, quais seriam os três objetivos mais viáveis para o projeto? (iii) a partir dos três objetivos selecionados, quais seriam as questões de pesquisa para serem exploradas? (iv) com todas as informações enviadas, quais seriam as palavras chaves mais adequadas para o projeto de pesquisa?

Foram escolhidas como palavras-chaves no processo de busca os seguintes termos: “*Cartographic Updating*”, “*UAV Imagery*”, “*Change Detection*”, “*Artificial Intelligence*”, “*Research Methods*” e “*Results Comparison*”. As buscas foram efetuadas nas bases de dados científicas *Web of Science*, *Scopus* e *ScienceDirect*. Justifica-se a utilização das bases devido ao ambiente de acesso para pesquisador e filtragem de dados adequada. Os critérios de exclusão dos trabalhos foram os seguintes: artigos de revisão, acesso antecipado, referências citadas enriquecidas, não categorias *Web of Science*. Já os critérios de inclusão foram: artigos de acesso livre e ano de publicação: 2020 a 2025. A Figura 1 apresenta o esquema de desenvolvimento das etapas adotadas.

Figura 1 – Etapas do processo metodológico da revisão integrativa



Fonte: Os autores (2025).

Embora os critérios de inclusão e exclusão tenham sido previamente definidos, é importante explicitar a lógica que orientou o processo decisório e a triagem dos artigos. A etapa de seleção envolveu a leitura dos títulos, resumos e, posteriormente, dos textos completos, considerando a pertinência temática ao escopo do estudo - isto é, o uso de DL aplicado a dados obtidos por RPAs com finalidades de mapeamento cartográfico.

O Quadro 1 apresenta a síntese dos principais critérios utilizados, acompanhados de sua descrição e justificativa metodológica. Essa abordagem permite compreender as razões das exclusões e o enquadramento dos artigos selecionados nas cinco categorias temáticas definidas (agricultura, detecção de objetos, incêndios, inspeções e LiDAR).

Quadro 1 - Critérios de inclusão e exclusão adotados na revisão integrativa

Tipo de critério	Descrição aplicada	Justificativa metodológica
Período de publicação	Artigos publicados entre 2020 e 2025	Representa o intervalo mais recente de consolidação das aplicações de DL e RPAs no mapeamento cartográfico.
Tipo de documento	Exclusão de revisões, <i>preprints</i> e relatórios técnicos	Garantir foco em pesquisas empíricas originais que apresentem resultados experimentais e metodologias replicáveis.
Idioma	Inclusão de artigos em inglês, português e espanhol	Abrangência internacional com ênfase em literatura científica acessível aos pesquisadores da área de geotecnologias.
Acesso ao documento	Inclusão preferencial de artigos de acesso livre (<i>open access</i>)	Favorecer transparência, reproduzibilidade e consulta pública das metodologias revisadas.
Fonte de dados	<i>Bases Web of Science, Scopus e ScienceDirect</i>	Representam os repositórios mais relevantes e consolidados nas áreas de Engenharia, Sensoriamento Remoto e Cartografia.
Temática principal	Aplicações de aprendizado profundo (DL) utilizando dados obtidos por RPAs	Assegurar pertinência direta ao objeto de estudo e eliminar artigos que utilizem apenas satélites, sensores terrestres ou aprendizado de máquina tradicional.
Categorização temática	Classificação final dos artigos em cinco grupos: agricultura, detecção de objetos, incêndios, inspeções e LiDAR	Facilitar análise comparativa e síntese integrativa das tendências de aplicação e arquiteturas empregadas.

Elaboração: Os autores (2025).

Após a triagem final, procedeu-se à leitura integral e à extração sistemática de informações dos 22 artigos incluídos. Foram identificados, para cada estudo, o tipo de sensor embarcado, a arquitetura de rede neural utilizada, a área de aplicação, o tipo de dado (RGB, multiespectral, térmico ou LiDAR), os principais resultados obtidos e as limitações relatadas pelos autores.

Essas informações foram organizadas em planilhas comparativas e sintetizadas qualitativamente por meio de análise temática, considerando convergências, inovações metodológicas e lacunas técnicas. O processo de integração dos resultados baseou-se na categorização dos estudos em cinco eixos temáticos - agricultura, detecção de objetos, inspeções, incêndios e LiDAR - permitindo a identificação de tendências e padrões recorrentes nas aplicações de aprendizado profundo com RPAs.

Essa etapa de extração e integração consolidou o caráter interpretativo e reflexivo da revisão integrativa, garantindo coerência entre o objetivo da pesquisa e a análise crítica dos trabalhos revisados.

2.2 Técnica de seleção da pesquisa

As *strings* de busca utilizadas nas 3 bases de dados a partir das palavras chaves foram ("*LiDAR*" OR "*Deep Learning*" OR "*Artificial Intelligence*" OR "*Cartographic Change Detection*" OR "*UAV*" OR "*UAS*").

Aplicando a *string* na base de dados *Web of Science* o resultado após os critérios de inclusão e exclusão foram de 123 artigos. Para a base de dados *Scopus* o resultado foi de 42 artigos. E finalmente para a base de dados *ScienceDirect* o quantitativo de pesquisas foi de 47 artigos, conforme Tabela 1. Cabe destacar que mesmo com a etapa de depuração foi feito um novo filtro nos artigos no *Zotero* (*software* de gerenciamento de artigos), para excluir artigos com temáticas semelhantes.

Tabela 1 - Quantitativo de Artigos Identificados nas Bases Científicas

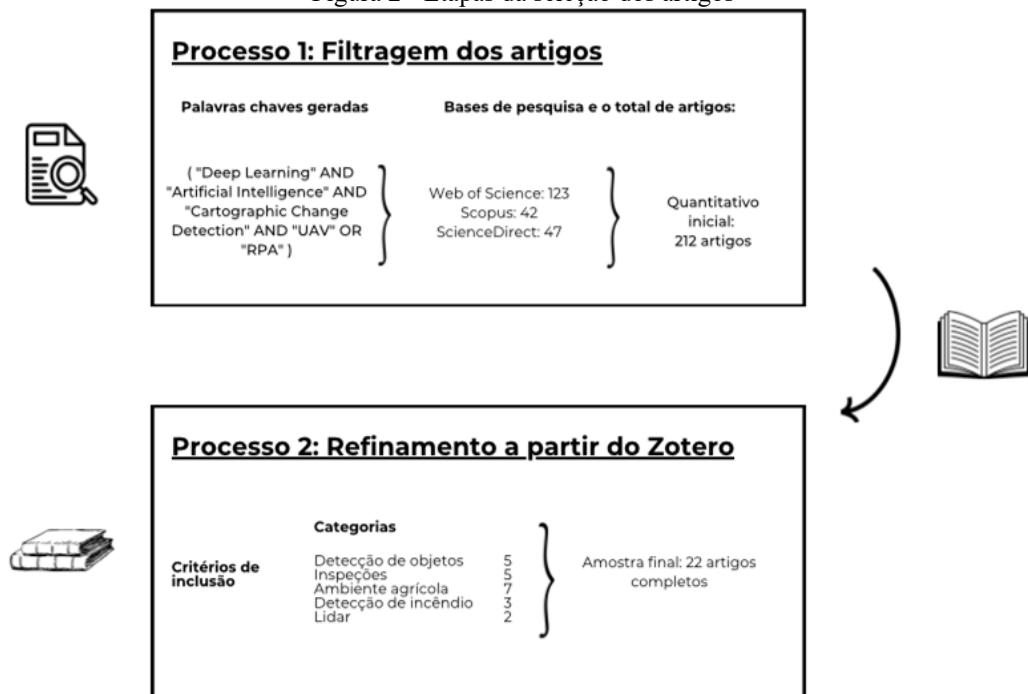
Base de dados	Artigos identificados	Artigos incluídos após triagem	Percentual de inclusão (%)
Web of Science	123	8	6,5
Scopus	42	9	21,4
ScienceDirect	47	5	10,6
Total	212	22	10,3

Elaboração: Os autores (2025).

As categorias temáticas foram definidas a partir da recorrência de aplicações identificadas nos estudos

selecionados, combinando critérios tecnológicos (tipo de sensor e arquitetura de rede) e finalidades cartográficas (mapeamento agrícola, inspeção de infraestrutura, detecção de objetos, monitoramento ambiental e uso de LiDAR). Essa categorização permitiu organizar os resultados e facilitar a análise comparativa e interpretativa das tendências de aplicação, resultando na seleção de 22 artigos considerados mais aderentes ao escopo da pesquisa, de acordo com a Figura 2.

Figura 2 - Etapas da seleção dos artigos



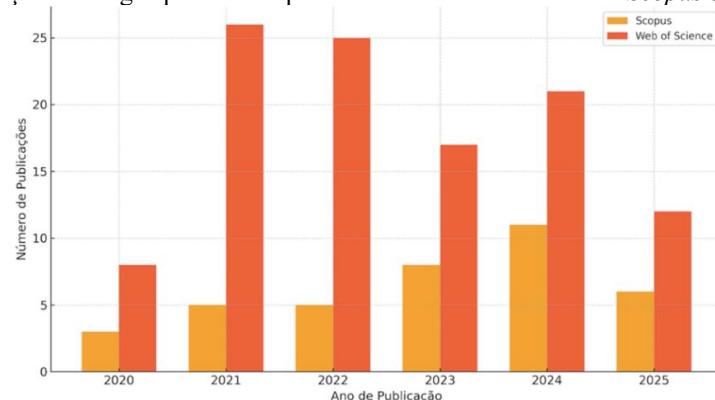
Elaboração: Os autores (2025).

3 ANÁLISE DOS RESULTADOS

3.1 Análise dos artigos por período e local de publicação

Com os resultados obtidos, foi possível compreender o amplo uso de RPAs embarcados com sensores RGB, termais, multiespectrais, ou LiDAR integrados com as mais variadas redes neurais convolucionais. Dessa forma, percebeu-se a importância dessas redes e seu aprimoramento constante para os diversos fins, nota-se a quantidade de publicações de artigos por ano de acordo com a Figura 3, além disso ficou evidente a ausência da barra correspondente a base *ScienceDirect* no gráfico, pois, diferentemente das bases *Web of Science* e *Scopus*, suas informações não estavam acessíveis.

Figura 3 - Relação de artigos publicados por ano entre as bases de dados *Scopus* e *Web of Science*



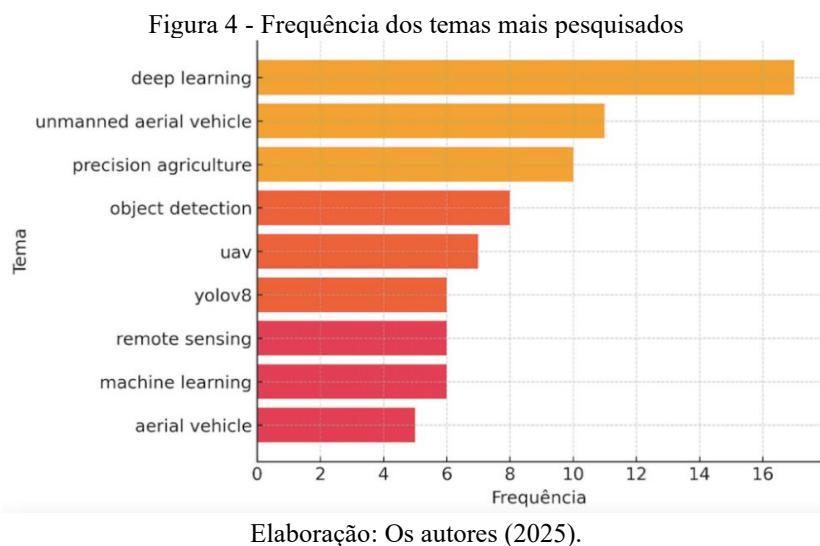
Fonte: Os autores (2025).

É notória a quantidade de artigos que utilizam dados de RPAs, integrados com DL para diversos fins, isso provavelmente está associado a disponibilidade desse equipamento que tem se popularizado com aplicações em diferentes áreas de conhecimento.

A distribuição geográfica das publicações revelou concentração expressiva na China, seguida por Estados Unidos e Índia. Esse resultado corrobora análises anteriores que destacam o protagonismo da China na área de Inteligência Artificial (IA) e sensoriamento remoto, fruto de investimentos governamentais robustos, integração com o setor privado e políticas de incentivo à inovação tecnológica (Tiwari et al., 2022). De modo semelhante, Alotaibi e Nassif (2024) destacam o protagonismo desses países na aplicação de IA e *machine learning* ao monitoramento ambiental, enquanto Yigitcanlar et al. (2024b) relacionam tal liderança às políticas nacionais de fomento e adoção tecnológica. Assim, a predominância observada reflete tanto o incentivo científico quanto a infraestrutura tecnológica necessária para pesquisas envolvendo RPAs e algoritmos DL.

3.2 Análise dos artigos pelos temas mais frequentes

Os dados extraídos dos artigos permitiram obter informações sobre os temas mais pesquisados e discutidos. A Figura 4 expõe as temáticas por sua frequência.



O termo *Unmanned Aerial Vehicle* (*Aeronave não tripulada*) assim como *RPAs* foi o segundo mais pesquisado, depois *Precision Agriculture* (Agricultura de precisão), logo em seguida *Object Detection* (Detecção de Objetos). Verifica-se que o DL está intrinsecamente relacionado com o avanço das pesquisas que envolvem uso de RPAs, seja para inspeções, detecção de objetos, detecção de incêndios, classificação automática de nuvem de pontos proporcionadas por dados LiDAR, análises preditivas em ambientes agrícolas, entre outros processos.

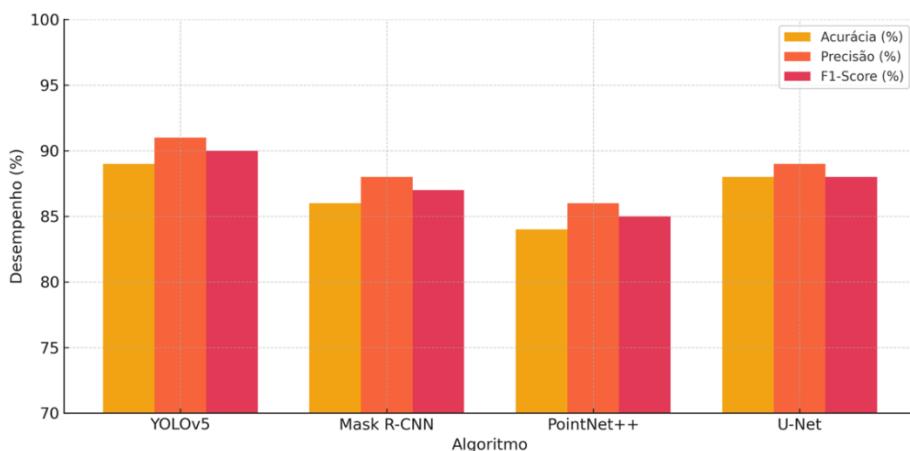
3.3 Análise dos artigos pelos indicadores das redes neurais convolucionais utilizadas

Na análise das arquiteturas de redes neurais convolucionais utilizadas nos artigos selecionados (Figura 5), verificou-se predominância das redes da família YOLO, seguidas de U-Net, DeepLab e outras CNNs específicas. Métodos de *machine learning* tradicionais, como *Random Forest* (RF) ou *Support Vector Machines* (SVM), não foram considerados na análise final, uma vez que não se enquadram na definição de DL. A presença desses algoritmos em versões preliminares da revisão decorreu da abrangência inicial da chave de busca, que incluiu termos mais amplos de IA. Essa limitação foi corrigida, de modo a assegurar que apenas estudos baseados em arquiteturas de DL integradas a RPAs fossem contemplados. Sobre a família YOLO, constatou-se o seu elevado desempenho, especialmente as versões YOLOv5, YOLOv8 e posteriores, amplamente aplicadas em tarefas de detecção em tempo real. Atualmente, a versão mais recente disponível é a YOLOv12 (2025), que apresenta avanços em eficiência computacional e precisão em contextos complexos

de detecção. Esse contínuo desenvolvimento evidencia a rápida evolução das arquiteturas de DL e sua consolidação como ferramenta central em aplicações com RPAs. Um outro algoritmo de código aberto e que obteve um bom resultado foi o *Deepness* (*plugin* do QGIS), desenvolvido por Aszkowski et al. (2023), onde numa ortofoto de 17,6 ha, o algoritmo conseguiu segmentar 208 feições, a partir deste resultado foi gerado um resumo para o XII Colóquio de Ciências Geodésicas na UFPR, apresentado por estes autores em novembro de 2024.

Além do *Deepness*, destacam-se outras ferramentas e bibliotecas que empregam técnicas de DL para segmentação semântica e classificação de imagens geográficas, como o *Detectree2*, focado na identificação de copas arbóreas, o *plugin* experimental da Kartosa para QGIS, e bibliotecas externas como *TorchGeo* ligada ao ecossistema *PyTorch* e *Raster Vision*, que oferecem *pipelines* robustas para treinamento e inferência de modelos em dados de sensoriamento remoto. Essas soluções têm expandido o leque de aplicações de IA na cartografia, promovendo maior automação e precisão em tarefas tradicionalmente manuais de segmentação.

Figura 5 – Arquiteturas de redes neurais convolucionais utilizadas



Elaboração: Os autores (2025).

O resultado obtido pela segmentação possibilita análises valiosas para atualização cartográfica, pois traz consigo a temporalidade, pois se há uma ortofoto anterior é possível comparar inequivocamente o que mudou numa edificação, ou numa área ambiental, se houve desmatamento ou se a vegetação se regenerou.

3.4 Aplicações em detecção de objetos

Este tópico discute os trabalhos selecionados que exploram o uso de técnicas de Deep Learning (DL) aplicadas a imagens adquiridas por RPAs, com foco em diferentes problemas de mapeamento e detecção automática. Para facilitar a leitura, os estudos são apresentados por área de aplicação, destacando as principais inovações metodológicas e os desafios associados ao uso dessas tecnologias.

No contexto da detecção de pequenos alvos em ambientes rodoviários, Aibibu et al. (2024) propõem uma rede convolucional denominada ERGW-net (Gaussian-Wasserstein de estilo repetitivo), desenvolvida especificamente para melhorar a precisão na identificação de alvos de pequena dimensão em imagens aéreas de infravermelho. O conjunto de dados foi obtido com o uso de um RPA DJI Matrice M210 V2, equipado com uma câmera termal DJI Zenmuse XT2, com resolução de 640×512 pixels e lente de 25 mm, o que demonstra a integração entre sensores especializados e modelos de DL para monitoramento contínuo de estradas, inclusive em condições de baixa luminosidade.

Ainda no campo de aplicações práticas, mas com foco em infraestrutura de software, Aszkowski et al. (2023) desenvolvem um *plugin* open source para o QGIS que permite a aplicação direta de redes neurais convolucionais sobre qualquer camada raster, seja ela uma matriz numérica ou uma imagem. O *plugin* suporta tarefas de regressão, segmentação e detecção de alvos, além de disponibilizar um repositório de modelos pré-treinados que podem ser adaptados a diferentes contextos de pesquisa, reduzindo a barreira técnica para o uso de DL em rotinas de geoprocessamento.

No que se refere à detecção de objetos em imagens aéreas, Li et al. (2023a) abordam um dos principais

desafios dessa tarefa: a identificação confiável de alvos pequenos, cuja representação limitada em pixels tende a resultar em erros de interpretação e detecção incompleta. Os autores propõem um modelo de detecção inspirado na arquitetura YOLOv8-s, visando melhorar o desempenho em tempo real na detecção de objetos em imagens aéreas, com resultados considerados satisfatórios e promissores para aplicações que exigem resposta rápida.

A aplicação de DL no monitoramento ambiental também é evidenciada no estudo de Park et al. (2024), que compara o desempenho do modelo YOLOv8 e do DeepLabv3+ na detecção e reconhecimento de pilhas de resíduos sólidos provenientes de atividades humanas, as quais representam potenciais fontes de poluição de aquíferos. A análise qualitativa indica que o YOLOv8 apresenta desempenho superior tanto na detecção quanto na classificação dessas pilhas, sugerindo que a integração entre RPAs e DL pode contribuir para sistemas mais eficientes de controle, monitoramento e logística de gestão de resíduos em ambientes aquáticos e suas áreas de influência.

Por fim, Soeleman et al. (2023) investigam o uso de modelos de aprendizagem profunda aplicados a imagens termais obtidas por RPAs equipados com câmeras térmicas embarcadas, com ênfase na detecção de objetos em condições noturnas. Nesses cenários, a baixa luminosidade torna insuficiente o uso de câmeras RGB convencionais, enquanto os sensores termais operam a partir da radiação emitida pelos alvos. As análises são conduzidas com base no conjunto de dados público HIT-UAV, composto por 2.898 imagens e múltiplas classes (pessoa, carro, bicicleta, veículos, animais, entre outras), demonstrando o potencial das imagens termais combinadas com DL para reconhecimento de objetos em contextos de vigilância, segurança e monitoramento noturno.

As principais vantagens e lacunas das pesquisas mencionadas são apresentadas no Quadro 2 abaixo.

Quadro 2 - Síntese dos artigos sobre detecção de objetos

Autores	Ano	Objetivo	Vantagem	Lacuna
Aibibu et al.	2024	Desenvolver uma rede neural eficiente para aplicações de detecção usando estilo Rep e redes Gaussian–Wasserstein.	Alta eficiência no processamento de dados complexos.	Escalabilidade da aplicação em ambientes com dados limitados.
Aszkowski et al.	2023	Apresentar o plugin "Deepness" para QGIS, focado em sensoriamento remoto profundo com redes neurais.	Integração simples com o QGIS, ampliando as capacidades de sensoriamento.	Necessidade de aprimorar a interface para suportar mais funcionalidades de IA.
Li et al.	2023	Modificar a rede YOLOv8 para melhorar a detecção de objetos em imagens aéreas capturadas por RPA.	Aumento da precisão em detecção de objetos pequenos.	Adaptação da rede para diferentes cenários de detecção de objetos.
Park et al.	2024	Desenvolver um sistema de detecção e classificação de compostagem usando RPA e IA.	Melhora na precisão de classificação de compostagem.	Generalização do sistema para diferentes tipos de compostagem.
Soeleman e Supriyanto	2023	Aplicar modelos de DL para detecção de objetos em imagens térmicas obtidas por RPA em condições noturnas	Melhora a precisão na detecção de múltiplas classes de objetos em imagens térmicas noturnas.	Aplicação ainda limitada a um único conjunto de dados e cenários; necessita validação em diferentes ambientes.

Elaboração: Os autores (2025).

3.5 Resumos das aplicações nas mais diversas inspeções

No âmbito da inspeção de infraestruturas lineares, Jeon et al. (2024) propõem uma metodologia inovadora para otimização de voo autônomo em instalações de transmissão aérea de energia. A estratégia de voo emprega informações multimodais provenientes de sensores 3D LiDAR e de uma câmera óptica: enquanto o 3D LiDAR fornece informações geométricas tridimensionais detalhadas do entorno das estruturas, a câmera óptica complementa esses dados com atributos visuais, resultando em uma representação mais precisa das linhas de transmissão. Para aprimorar o processo de inspeção, os autores introduzem ainda uma nova rede neural profunda, denominada RoMP (rotational bounding box with multi-level feature pyramid transformer), voltada à detecção de objetos. Esse modelo permite que o RPA ajuste altitude e direção de forma autônoma, rastreando a linha de transmissão com maior precisão e segurança.

Em uma perspectiva distinta, focada na caracterização geológica, Nakamura et al. (2024) realizam um

levantamento quantitativo de afloramentos em três áreas costeiras do Japão, com o objetivo de estimar a relação entre a morfologia da superfície e as informações visuais de rochas bem expostas, por meio de aerofotogrametria com drones. A partir dos dados adquiridos, são gerados modelos digitais tridimensionais dos afloramentos, utilizados para produzir imagens no espaço de cores HSV (matiz, saturação e valor) e modelos digitais de elevação (DEM), além do cálculo do índice de rugosidade do terreno (TRI) a partir do DEM. Com esses insumos, um modelo de aprendizado de máquina (MLM) é treinado para prever a rugosidade da superfície em escala milimétrica. O erro quadrático médio obtido (0,0051) indica que o algoritmo alcança previsões de rugosidade consideradas razoáveis para aplicações geocientíficas.

Pan et al. (2024) abordam o problema do planejamento de rotas de inspeção sob incertezas de recursos e restrições provenientes de múltiplas fontes, propondo uma abordagem baseada em aprendizagem por reforço profundo (DRL). Os autores introduzem uma nova rede neural profunda baseada em atenção, denominada A-DNN, projetada para aprender estratégias ótimas de rotas. A arquitetura da A-DNN é composta por um codificador e um decodificador duplos, especificamente voltados para cenários de inspeção com RPA. O modelo é comparado com outros algoritmos, como o método de atenção multi-cabeça dupla (DAM), em simulações e em um estudo de caso envolvendo inspeções em parques eólicos. De modo geral, a abordagem em DRL demonstra potencial para apoiar a tomada de decisão na escolha de metodologias de inspeção mais eficientes, fornecendo soluções adaptáveis e interpretáveis para RPAs em ambientes de engenharia complexos e dinâmicos.

Com foco na inspeção de sinalização viária, Rahnamayiezekavat et al. (2024) propõem uma plataforma baseada em RPA para enfrentar limitações de acesso, ineficiência operacional e dificuldades de processamento de imagens digitais nos sistemas tradicionais de monitoramento de marcações rodoviárias. No estudo, são utilizadas imagens com resolução de 5472×3080 pixels e distância focal de 8,8 mm. O processamento das imagens emprega o algoritmo de agrupamento K-means, explorando as diferenças de intensidade entre os pixels das pinturas de sinalização e o fundo de asfalto. Para avaliação da qualidade da pintura, é aplicado o método de limiarização de Otsu. A pesquisa é conduzida inicialmente em uma área piloto (um estacionamento), com a perspectiva de ampliar a aplicação da metodologia para escala urbana em estudos futuros.

Por sua vez, Zhao et al. (2024) desenvolvem uma metodologia de navegação autônoma para RPAs voltada à detecção de anomalias em oleodutos e gasodutos, fundamentada em uma versão aprimorada do algoritmo YOLOv7. A cadeia de processamento inclui o uso do detector de bordas de Canny para realçar as bordas dos dutos e a aplicação da transformada de Hough para identificar segmentos lineares correspondentes ao traçado dos oleodutos ou gasodutos. Um RPA inteligente do modelo P600 é empregado para inspecionar as conexões de petróleo e gás ao longo da infraestrutura, orientado pelas saídas do modelo treinado com YOLOv7. Os autores destacam que a definição clara da metodologia e dos dados utilizados favorece comparações justas em avaliações de inspeção em trabalhos futuros.

As principais vantagens e lacunas identificadas nesses estudos são sintetizadas e discutidas no Quadro 3.

Quadro 3 - Síntese dos artigos sobre aplicações de inspeções

Autores	Ano	Objetivo	Vantagem	Lacuna
Jeon et al.	2024	Desenvolver uma estratégia de voo autônomo para veículos aéreos não tripulados (RPAs).	Maior eficiência na execução de missões autônomas.	Aplicação limitada em ambientes com infraestrutura limitada ou complexa.
Nakamura et al.	2024	Estimar a rugosidade superficial em escala milimétrica de rochas usando RPAs.	Alta precisão na estimativa de rugosidade em superfícies naturais.	Expansão da metodologia para diferentes tipos de superfícies e materiais.
Pan et al.	2024	Desenvolver uma rota de colaboração entre veículos aéreos não tripulados e humanos.	Melhora na coordenação e eficiência entre RPAs e operadores humanos.	Integração de sistemas para maior autonomia dos RPAs em ambientes adversos.
Rahnamayiezekavat et al.	2024	Avaliar a integridade da marcação de pavimento usando técnicas automatizadas.	Aumento da precisão e velocidade na avaliação de marcas viárias.	Adaptação a diferentes tipos de marcação e condições ambientais variáveis.
Zhao et al.	2024	Desenvolver um sistema de inspeção de gasodutos usando RPAs e visão computacional.	Melhoria na segurança e eficiência das inspeções de infraestrutura crítica.	Expansão da metodologia para diferentes tipos de infraestruturas além de gasodutos.

Elaboração: Os autores (2025).

3.6 Resumos das aplicações em ambiente agrícola

A categoria de aplicações agrícolas reúne estudos que exploram o potencial combinado de RPAs, sensores multiespectrais/RGB e técnicas de aprendizado de máquina e de deep learning para monitoramento de culturas, previsão de rendimento e apoio ao manejo agrícola de precisão.

Yuan (2024) apresenta o AriAplBud, um acervo de imagens de botões de flores de macieira obtidas em diferentes ângulos por uma câmera RGB embarcada em um RPA. O conjunto reúne 3.600 imagens de botões em seis estágios de crescimento, a partir das quais foram geradas 110.467 anotações de caixas delimitadoras, utilizadas como amostras positivas. Além disso, foram incluídas 2.520 imagens de pomares vazios, sem botões de flores, como amostras negativas. Os resultados mostram que o AriAplBud pode ser integrado a distintos modelos de detecção de objetos, uma vez que adota o formato de anotação Darknet, compatível com a estrutura do YOLOv8, o que amplia sua aplicabilidade em tarefas de detecção automática no contexto da fruticultura.

No trabalho de Fei et al. (2021), são investigadas as capacidades de imagens multiespectrais obtidas por RPAs, combinadas com métodos de aprendizado de conjunto, para aumentar a precisão da previsão de rendimento de grãos em programas de melhoramento. Os autores desenvolvem uma estrutura de ensemble learning que integra diferentes modelos de base, incluindo floresta aleatória (RF), máquina de vetores de suporte (SVM), processo gaussiano (GP) e regressão de crista (RR). Os melhores resultados de previsão de rendimento de grãos são observados no estágio intermediário de enchimento de grãos, sob condições de irrigação total. O estudo também aponta que futuros avanços em DL podem acelerar o uso de dados multiespectrais baseados em RPAs na predição precisa de características agronômicas complexas, como o rendimento de trigo.

O trabalho de Skobalski et al. (2024) tem como objetivo analisar a transferibilidade e o desempenho de modelos de previsão de rendimento voltados ao melhoramento de soja em locais de teste distribuídos nas Américas do Norte e do Sul. Para isso, são avaliadas diferentes técnicas de aprendizado de máquina, incluindo Random Forest Regressor (RF), Gradient Boosting Regression (GB) e Deep Neural Networks (DNN), em experimentos conduzidos sob distintas condições climáticas e de crescimento. Os autores propõem uma nova metodologia de aprendizado de transferência para apoiar a seleção de genótipos e a categorização do rendimento da soja, visando à triagem de variedades de alto desempenho. Adicionalmente, investigam a importância da resolução temporal na previsão de rendimento, explorando estágios críticos do desenvolvimento da cultura e diferentes frequências de aerolevantamento. Ao todo, 31.404 amostras são utilizadas para o treinamento dos modelos, evidenciando a robustez da base de dados empregada.

No estudo de Li et al. (2023b), a hipótese central é que a precisão na previsão do rendimento de culturas pode ser aprimorada pela integração de dados multiespectrais obtidos por RPAs com algoritmos de aprendizado profundo. Os autores desenvolvem 16 índices de vegetação sensíveis ao rendimento, cujas relações são analisadas com base em dados multiespectrais de trigo de inverno coletados nos estágios de espigamento, floração e enchimento de grãos. O monitoramento detalhado ao longo do período reprodutivo é considerado estratégico para a tomada de decisão na produção agrícola. A partir da combinação dos dados desses três estágios, são definidos sete conjuntos de variáveis de entrada, utilizados em quatro algoritmos generalizados de aprendizado de máquina - Random Forest (RF), K-Nearest Neighbor (KNN), Bagging e Gradient Boosting Regression (GBR) - e em um modelo de aprendizado profundo do tipo 1D Convolutional Neural Network (1D-CNN). Os resultados indicam que o modelo CNN apresenta a melhor precisão de previsão entre as abordagens testadas, reforçando o potencial do deep learning neste tipo de aplicação.

Hooshyar et al. (2024) propõem uma solução baseada em imagens de RPAs para detecção de espécies arbóreas e classificação de árvores frutíferas em terrenos íngremes e de difícil acesso. Para isso, são utilizados RPAs equipados com câmeras multiespectrais e RGB, permitindo a geração de ortomosaicos que subsidiam a classificação em diferentes categorias, como árvores frutíferas, estradas e edificações. Em paralelo, são aplicadas redes neurais convolucionais (CNN) para reconhecimento de padrões nas imagens, testando-se as arquiteturas VGG-16, VGG-19 e ResNet-50. Entre os modelos avaliados, o VGG-16 apresenta os resultados mais precisos na análise de imagens multiespectrais. Os autores destacam que a abordagem proposta pode

contribuir para o gerenciamento mais eficiente de cultivos de frutas em áreas acidentadas.

No trabalho de Mohammadi et al. (2024), é explorado o potencial de RPAs equipados com sensores multiespectrais e RGB para fenotipagem de plantas em pesquisas agrícolas. A fenotipagem, neste caso, está relacionada à altura das plantas, à previsão de rendimento e ao teor de clorofila. Os experimentos envolvem 38 cultivos de fava (*Vicia faba L.*), conduzidos em quatro repetições no sudeste da Noruega. Para estimar os valores de produtividade, são utilizados modelos de Regressão de Vetores de Suporte (SVR) e Random Forest (RF), alimentados por combinações de bandas multiespectrais, índices de vegetação e estimativas de altura das plantas derivadas de dados de RPAs em quatro estágios de desenvolvimento da cultura. A forte correlação entre as medições manuais e as alturas estimadas via RPA ($R^2 = 0,97$) demonstra alta aderência entre os métodos. Os resultados indicam que a integração de RPAs com câmeras RGB e multiespectrais, combinada a algoritmos de aprendizado de máquina, constitui uma abordagem precisa para quantificar características agronomicamente relevantes em fava.

Por fim, Yu et al. (2021) investigam o uso de imagens multiespectrais obtidas por RPAs, índices de vegetação (VI), altura da cultura, métricas topográficas e propriedades do solo para previsão do peso de nitrogênio de dossel (g/m^2) em um campo de milho no sudoeste de Ontário, Canadá. Os modelos de treinamento empregados são a floresta aleatória (RF) e a regressão de vetores de suporte (RVS). Com base nesses modelos, 29 amostras são selecionadas para avaliar a capacidade de predição do peso de nitrogênio no dossel. Os resultados mostram desempenho superior da RF em relação à RVS, com uso de 15 variáveis selecionadas (de altura, espectrais e topográficas), alcançando R^2 de 0,73 e erro quadrático médio (RMSE) de 2,21 g/m^2 .

O Quadro 4, a seguir, apresenta a síntese das principais características, vantagens e limitações dos artigos incluídos nesta categoria de aplicações agrícolas.

Quadro 4 - Síntese dos artigos sobre aplicações agrícolas

Autores	Ano	Objetivo (resumido)	Vantagem (resumida)	Lacuna (resumida)
Yuan et al.	2024	Criar dataset de botões de flores de macieira com imagens de RPA para detecção.	Disponibiliza base anotada e padronizada para treinar e comparar modelos de detecção.	Restrito a uma espécie e região, precisa teste em outras culturas e contextos.
Fei et al.	2021	Prever rendimento de trigo com imagens multiespectrais de RPA.	Ensemble melhora a acurácia de predição em estágios fenológicos chave.	Integrar deep learning e avaliar sob diferentes climas e manejos.
Skobalski et al.	2024	Avaliar a transferibilidade de modelos de rendimento de soja em vários sítios.	Mostra potencial de transferência entre ambientes das Américas do Norte e do Sul.	Ampliar para outras regiões, culturas e uso operacional em apoio à decisão.
Li et al.	2023	Comparar 1D CNN com modelos tradicionais na predição de trigo de inverno.	1D CNN atinge maior acurácia com dados multiespectrais de RPA.	Validar em bases maiores e em distintos contextos agroecológicos.
Hooshyar et al.	2024	Detectar e classificar árvores frutíferas em encostas com imagens de RPA.	Alta acurácia na identificação de árvores em terrenos íngremes.	Otimizar desempenho sob diferentes iluminações e sensores.
Mohammadi et al.	2024	Aprimorar a fenotipagem de feijão fava com RPA e aprendizado de máquina.	Aumenta eficiência e precisão de variáveis fenotípicas a campo.	Testar a abordagem em outras espécies e cenários de melhoramento.
Yu et al.	2021	Estimar nitrogênio no dossel de milho com variáveis derivadas de RPA.	Bom desempenho do Random Forest com conjunto reduzido de variáveis.	Explorar novos sítios e métricas para melhorar generalização e acurácia.

Elaboração: Os autores (2025).

3.7 Resumo das aplicações em detecção de incêndios

Os estudos desta categoria exploram o potencial de RPAs combinados com técnicas de deep learning para detecção precoce de incêndios florestais e mapeamento de áreas queimadas, com foco em precisão, resposta rápida e generalização espacial.

No trabalho de Saydirasulovich et al. (2023) desenvolvem um modelo de treinamento baseado no YOLOv8 voltado à detecção precisa de fumaça de incêndios florestais em imagens adquiridas por RPAs. Para

aprimorar a capacidade de localização dos alvos, os autores incorporam o modelo de regressão Wise-IoU (WIou), aumentando a precisão na delimitação espacial das regiões de interesse. Além disso, integram o mecanismo BiFormer, que orienta a atenção do modelo para as características específicas da fumaça em cenários florestais. A análise dos resultados demonstra a eficácia do YOLOv8, ajustado com essas melhorias, na detecção de fumaça, o que reforça seu potencial para aplicações operacionais de monitoramento e alerta precoce.

Em uma abordagem complementar, Shamta e Demir (2024) propõem um sistema de vigilância dedicado à detecção precoce de incêndios florestais, também fundamentado em aprendizado profundo aplicado a imagens de RPAs. O núcleo do sistema é uma rede neural do tipo CNN-RCNN, treinada para classificar áreas com e sem fogo. Para viabilizar o uso em campo, os autores desenvolvem uma interface de estação terrestre responsável por receber e exibir, em tempo quase real, as imagens e as coordenadas georreferenciadas dos focos detectados, facilitando a rápida intervenção das equipes de resposta. O RPA executa missões de voo planejadas e conta com a integração do dispositivo NVIDIA Jetson Nano, utilizado como plataforma de hardware embarcado para processamento de dados e detecção de incêndios em tempo real, o que evidencia a viabilidade de soluções embarcadas em cenários operacionais.

Por sua vez, Sui et al. (2024) apresentam uma abordagem voltada ao mapeamento de áreas queimadas, propondo um novo esquema de pré-treinamento baseado em U-Net, denominado BiAU-Net. O modelo incorpora mecanismos de atenção que permitem focar em regiões associadas a cicatrizes de queimadas, aumentando a precisão e a eficiência na segmentação. Uma das principais vantagens do BiAU-Net é o uso explícito de mudanças temporais, a partir de duas imagens Sentinel-2 (pré e pós-incêndio), o que melhora o desempenho em diferentes contextos ambientais. Cinco áreas independentes, distribuídas em distintos continentes, são selecionadas para a pesquisa: uma destinada ao treinamento do modelo e as demais utilizadas para teste, de modo a demonstrar sua capacidade de generalização. A validação é realizada com o produto Fire Disturbance Climate Change Initiative v5.1 da Agência Espacial Europeia, e os resultados indicam que o BiAU-Net supera significativamente esse referencial, com melhorias de 11,56%, evidenciando seu potencial para monitoramento global de queimadas.

Quadro 5 - Síntese dos artigos sobre detecção de incêndios

Autores	Ano	Objetivo	Vantagem	Lacuna
Saydirasulovich et al.	2023	Melhorar a detecção de fumaça de incêndios florestais usando YOLOv8.	Redução significativa de falsos positivos, maior precisão.	Necessidade de adaptação para detecção noturna e uso em dispositivos de borda.
Shamta & Demir	2024	Desenvolver um sistema de vigilância baseado em aprendizado profundo para detecção de incêndios florestais.	Alta precisão na detecção de incêndios com YOLOv5 e YOLOv8.	Necessidade de melhorias na robustez do sistema em implementações de campo em tempo real.
Sui et al.	2024	Detectar áreas queimadas usando U-Net e modelos bitemporais.	Melhora significativa na detecção de áreas queimadas com atenção às margens.	Otimizar a detecção em cenários com menor resolução temporal, como Nairobi e Sumatra.

Elaboração: Os autores (2025).

3.8 Resumos das aplicações em LiDAR aerotransportado

Na interface entre sensoriamento remoto e ecologia florestal, Lang et al. (2025) compararam três metodologias para mensuração da fração de lacunas no dossel: (i) análise de quadros extraídos de vídeos capturados por RPAs, (ii) fotografia hemisférica digital obtida abaixo do dossel e (iii) varredura por Light Detection and Ranging (LiDAR). O objetivo é avaliar a precisão e a aplicabilidade dessas técnicas em diferentes ângulos zenitais. Os autores identificam uma relação linear moderada entre os dados derivados de RPA e a referência obtida com fotografia hemisférica ($R^2 = 0,67$), com discrepâncias mais pronunciadas nas bordas das lacunas. Os resultados mostram que, embora os drones constituam uma alternativa mais econômica e ágil, sua acurácia diminui em ângulos zenitais baixos quando comparados ao LiDAR. A principal contribuição do estudo está na avaliação integrada dessas tecnologias, evidenciando seus pontos fortes e limitações em contextos florestais, com implicações diretas para o planejamento de missões de mapeamento e

estratégias de monitoramento ambiental.

Na fronteira do desenvolvimento de modelos para dados tridimensionais, Lu et al. (2025) propõem o 3D-UMamba, uma rede neural para segmentação semântica de nuvens de pontos LiDAR de múltiplas fontes, que integra o modelo Mamba à arquitetura U-Net. A inovação central consiste na capacidade de capturar informações contextuais globais com complexidade computacional linear, contornando limitações de desempenho típicas de abordagens baseadas em transformers. Por meio de uma estratégia de serialização de tokens baseada em voxelização (Voxel-based Token Serialization – VTS), o 3D-UMamba alcança elevada acurácia (mIoU superior a 84,5%) em diferentes conjuntos de dados LiDAR, incluindo cenários multiespectrais e urbanos. Os resultados demonstram a viabilidade do modelo para tarefas de segmentação complexas, destacando sua eficiência e adaptabilidade; como lacuna, os autores apontam a necessidade de testar o modelo em contextos dinâmicos e com elevados níveis de ruído para consolidar sua robustez em aplicações do mundo real.

Quadro 6- Síntese dos artigos sobre aplicações de LiDAR Aerotransportado

Autor	Ano	Objetivo	Vantagem	Desvantagem	Lacuna
Lang et al.	2025	Comparar a fração de lacunas no dossel florestal.	Drones fornecem cobertura rápida para estimativas de fração de lacunas em florestas.	Menor acurácia na estimativa das frações de lacunas em ângulos zenitais baixos.	Necessidade de otimizar algoritmos de interpretação de imagens de drones.
Lu et al.	2025	Desenvolver o 3D-UMamba, uma rede neural para segmentação semântica de nuvens de pontos LiDAR.	Maior eficiência e menor custo computacional comparado a Transformers.	Requer um processo de serialização de tokens (<i>Voxel-based Token Serialization</i>).	Explorar o desempenho do 3D-UMamba em cenários altamente dinâmicos.

Elaboração: Os autores (2025).

3.9 Resumo das abordagens com RPAs e detecção automática de defeitos em pavimentos

As contribuições de Peixoto et al. (2024) se destacam no avanço de metodologias para identificação de defeitos em pavimentos asfálticos, articulando abordagens tradicionais com inovações baseadas em inteligência artificial e sensoriamento remoto por RPAs. Os estudos desenvolvidos pelos autores abrangem desde análises comparativas entre métodos clássicos de levantamento visual e o uso de imagens aéreas até revisões bibliométricas sobre tecnologias emergentes aplicadas à detecção de patologias em pavimentos.

Em um dos trabalhos, evidencia-se a efetividade do uso de RPAs na captura de imagens para inspeções, com redução de tempo e de recursos quando comparado ao método tradicional, ainda que persistam limitações na identificação de determinados tipos de defeitos, como ondulações. Em outra vertente, os autores propõem uma técnica baseada no algoritmo YOLO para detecção automática de anomalias, reforçando o potencial do aprendizado de máquina na área de gestão e manutenção de pavimentos. A revisão bibliométrica conduzida pelo grupo mapeia as principais tendências internacionais, destacando a escassez de estudos nacionais com maior detalhamento metodológico e a ausência de normativas técnicas no Brasil que regulamentem o uso dessas ferramentas. Entre as lacunas apontadas, sobressaem-se a necessidade de validações em campo, o aprimoramento da resolução das imagens empregadas e o desenvolvimento de políticas públicas que integrem tecnologias digitais aos sistemas de gerenciamento de pavimentos.

Quadro 7 - Síntese das abordagens sobre RPAs e detecção automática de defeitos em pavimentos

Autor	Ano	Objetivo	Vantagem	Desvantagem	Lacuna
Peixoto et al.	2024	Identificar e analisar aplicações de IA e processamento de imagens na engenharia de transporte rodoviário.	Amplio panorama de pesquisas recentes em diferentes segmentos (infraestrutura, tráfego).	Falta de integração entre regiões e segmentos estudados.	Necessidade de mais estudos intersetoriais e articulação entre IA e políticas públicas no transporte.
		Analizar comparativamente métodos de identificação de defeitos em pavimentos asfálticos utilizando levantamento visual tradicional e imagens de drone.	Redução de tempo e recursos no uso de drones com resultados similares ao método tradicional.	Menor precisão na identificação de defeitos transversais como ondulações e afundamentos.	Melhoria na resolução e técnicas de análise das imagens para aumento da precisão.
		Realizar levantamento bibliométrico sobre tecnologias aplicadas à identificação de defeitos em pavimentos.	Mapeamento das principais tecnologias emergentes, especialmente uso de IA e YOLO.	Pouca produção nacional com detalhamento técnico aprofundado.	Falta de normas específicas para padronizar o uso de IA e aerolevantamentos em diagnósticos técnicos.
		Avaliar abordagens baseadas em aprendizado de máquina com imagens de drone para detecção de defeitos em pavimentos.	Proposta de nova técnica para aprimorar o sistema de inspeção rodoviária com YOLO.	Dependência da qualidade das imagens e da parametrização do voo para bons resultados.	Necessidade de validação em estudos de campo com diferentes condições ambientais.

Elaboração: Os autores (2025).

4 DISCUSSÃO

A análise integrativa dos 22 estudos, conduzida de acordo com a abordagem de Snyder (2019), permitiu sintetizar tendências, lacunas e perspectivas no uso de técnicas de aprendizado profundo aplicadas ao mapeamento cartográfico com imagens obtidas por RPAs. Observou-se que, embora a literatura apresente avanços significativos em desempenho e acurácia, persiste uma fragmentação metodológica relevante entre as abordagens, sobretudo quanto à padronização de dados, métricas de avaliação e procedimentos de validação cruzada.

Os resultados evidenciam o predomínio de arquiteturas baseadas em redes neurais convolucionais, como YOLO, U-Net e Mask R-CNN, amplamente empregadas pela eficiência em tarefas de detecção e segmentação de objetos. No entanto, poucos estudos detalham parâmetros de treinamento, número de épocas ou variações de learning rate, o que limita a reproduzibilidade dos experimentos. Além disso, há divergências na forma de mensuração da acurácia, com métricas como mAP, IoU e F1 Score utilizadas de maneira desigual. Essa falta de uniformidade compromete a comparabilidade entre os resultados e reforça a necessidade de protocolos metodológicos mais padronizados.

No campo das aplicações, a agricultura de precisão se destaca como a área mais consolidada, refletindo o amadurecimento do uso de RPAs na análise de culturas e na detecção de estresse hídrico. Em contraste, inspeções de infraestrutura e monitoramento de incêndios despontam como frentes emergentes, ainda carentes de estudos baseados em séries temporais e dados multisensoriais. O emprego de sensores LiDAR embarcados em RPAs também apresenta crescimento, indicando uma transição da análise exclusivamente espectral para a fusão de dados tridimensionais, o que amplia a precisão geométrica e temática dos produtos cartográficos.

Do ponto de vista técnico, observa-se um movimento de integração entre bibliotecas de código aberto, como PyTorch e TensorFlow, e ferramentas geoespaciais, como QGIS e Google Earth Engine. Essa interoperabilidade favorece o desenvolvimento de fluxos de trabalho automatizados e reproduzíveis. Apesar disso, a literatura ainda é incipiente quanto à adoção de boas práticas de documentação e disponibilização de código, o que afeta a transparência científica e dificulta a replicação dos experimentos. A criação de repositórios padronizados de dados geoespaciais e de modelos treinados desponta como estratégia promissora para mitigar essas limitações.

A análise dos estudos também evidenciou desafios éticos e epistemológicos associados ao uso de inteligência artificial em mapeamentos automatizados. Questões relativas à explicabilidade dos modelos, à privacidade dos dados capturados por RPAs e à responsabilidade na tomada de decisão cartográfica ainda são pouco exploradas. Essas lacunas apontam para a necessidade de incorporar a dimensão ética aos debates

técnicos, sobretudo quando os produtos gerados influenciam políticas públicas, ordenamento territorial e gestão ambiental.

De modo geral, os achados desta revisão confirmam que a aplicação de aprendizado profundo no mapeamento com RPAs constitui um campo em rápida expansão, mas ainda carente de maior padronização metodológica, de validação cruzada entre diferentes contextos geográficos e de integração com bases cartográficas oficiais. A heterogeneidade de sensores, resoluções e estratégias de anotação de dados reforça o caráter interdisciplinar e desafiador desse domínio.

Os resultados obtidos corroboram a literatura recente ao demonstrar que revisões integrativas são adequadas para mapear o grau de maturidade e as lacunas de pesquisa em áreas emergentes, conforme argumenta Snyder (2019). A consolidação de metodologias comparáveis e transparentes representa um passo essencial para a evolução científica do campo e para o fortalecimento da cartografia como disciplina orientada por evidências e por inovação tecnológica.

Os achados apresentados também reforçam a importância de institucionalizar protocolos nacionais de qualidade, interoperabilidade e ética na aplicação de inteligência artificial à cartografia. Ao articular tecnologias de aprendizado profundo e RPAs sob uma perspectiva cartográfica crítica, o Brasil tem potencial para consolidar uma agenda de pesquisa e inovação que une rigor técnico, responsabilidade social e soberania científica no campo das geotecnologias.

5 CONSIDERAÇÕES FINAIS

A presente revisão sistemática integrativa evidenciou que o uso de técnicas de DL aplicadas a imagens obtidas por RPAs vem se consolidando como um campo estratégico no mapeamento cartográfico contemporâneo. Entre 2020 e 2025, observou-se um avanço expressivo nas pesquisas voltadas à detecção, segmentação e classificação de feições, impulsionado pelo aprimoramento das arquiteturas de redes neurais convolucionais e pela popularização de plataformas de código aberto e sensores embarcados de alta resolução.

Os resultados demonstraram o predomínio das arquiteturas YOLO e U-Net, amplamente aplicadas em diferentes domínios, especialmente na agricultura de precisão, nas inspeções de infraestrutura e no monitoramento ambiental. Entretanto, a revisão também revelou limitações recorrentes, como a ausência de protocolos unificados para validação e comparação de resultados, a carência de dados abertos e a falta de documentação detalhada dos processos de treinamento e calibração. Tais lacunas comprometem a reproduzibilidade dos experimentos e dificultam a consolidação de padrões científicos para uso de DL no mapeamento cartográfico.

Além das questões técnicas, a análise destacou desafios éticos e epistemológicos associados à automação das interpretações cartográficas. O uso de RPAs e algoritmos de IA exige a incorporação de princípios de transparência, explicabilidade e responsabilidade social, sobretudo quando os produtos gerados subsidiam decisões espaciais de impacto público. A discussão sobre ética, interoperabilidade e confiabilidade dos modelos deve, portanto, integrar a agenda de pesquisa em cartografia e geotecnologias.

Esta revisão contribui ao sistematizar o estado da arte e ao propor diretrizes para o desenvolvimento de metodologias mais consistentes e reproduzíveis. Recomenda-se a criação de protocolos nacionais voltados à integração de DL, RPAs e práticas cartográficas, considerando padrões de qualidade, interoperabilidade e segurança de dados. Tais iniciativas podem fortalecer a capacidade de inovação científica e tecnológica do país no campo das geotecnologias, alinhando-se aos Objetivos de Desenvolvimento Sustentável (ODS) e às políticas de transformação digital.

Conclui-se que a consolidação de uma cartografia orientada pela inteligência artificial representa uma oportunidade ímpar para o Brasil avançar na modernização de suas infraestruturas de dados espaciais e na geração de produtos cartográficos mais precisos, atualizados e acessíveis.

Agradecimentos

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de mestrado (Processo: 88887.962009/2024-00) junto ao Programa de Pós-Graduação em Engenharia

Civil (PPEC), ao Grupo de Pesquisa em Informações Geoespaciais (GPGeo) e ao Laboratório de Fotogrametria e Sensoriamento Remoto (LabFSR) do Departamento de Engenharia de Transportes e Geodésia da Escola Politécnica da Universidade Federal da Bahia (UFBA).

Contribuição dos Autores

E. B. Oliveira foi responsável pela execução do estudo, incluindo a aquisição e o processamento inicial dos dados, a organização dos resultados, a redação do manuscrito e a edição final; V. de O. Fernandes definiu a abordagem metodológica, realizou a revisão crítica do conteúdo e supervisionou a pesquisa; e M. J. A. Júnior contribuiu com a curadoria dos dados, a análise formal e a revisão técnica do manuscrito.

Conflitos de Interesse

Os autores declaram que não há conflito de interesse.

Referências

Aibibu, T., Lan, J., Zeng, Y., Lu, W., & Gu, N. (2023). An Efficient Rep-Style Gaussian–Wasserstein Network: Improved UAV Infrared Small Object Detection for Urban Road Surveillance and Safety. *Remote Sensing*, 16(1), 25. <https://doi.org/10.3390/rs16010025>

Alotaibi, E., & Nassif, N. (2024). Artificial intelligence in environmental monitoring: in-depth analysis. *Discover Artificial Intelligence*, 4(1). <https://doi.org/10.1007/s44163-024-00198-1>

Aszkowski, P., Ptak, B., Kraft, M., Pieczyński, D., & Drapikowski, P. (2023). Deepness: Deep neural remote sensing plugin for QGIS. *SoftwareX*, 23, 101495. <https://doi.org/10.1016/j.softx.2023.101495>

Fei, S., Hassan, M. A., He, Z., Chen, Z., Shu, M., Wang, J., Li, C., & Xiao, Y. (2021). Assessment of Ensemble Learning to Predict Wheat Grain Yield Based on UAV-Multispectral Reflectance. *Remote Sensing*, 13(12), 2338. <https://doi.org/10.3390/rs13122338>

Hooshyar, M., Li, Y.-S., Chun Tang, W., Chen, L.-W., & Huang, Y.-M. (2024). Economic Fruit Trees Recognition in Hillsides: A CNN-Based Approach Using Enhanced UAV Imagery. *IEEE Access*, 12, 61991–62005. <https://doi.org/10.1109/access.2024.3391371>

Jeon, M., Moon, J., Jeong, S., & Oh, K. (2024). Autonomous flight strategy of an unmanned aerial vehicle with multimodal information for autonomous inspection of overhead transmission facilities. *Computer-Aided Civil and Infrastructure Engineering*, 39(14), 2159–2186. <https://doi.org/10.1111/mice.13188>

Lang, M., Antsov, M., Mumma, A., Suitso, I., Kuusk, A., & Piip, K. (2025). Comparison of forest canopy gap fraction measurements from drone-based video frames, below-canopy hemispherical photography, and airborne laser scanning. *European Journal of Remote Sensing*, 58(1). <https://doi.org/10.1080/22797254.2025.2456629>

Li, Y., Fan, Q., Huang, H., Han, Z., & Gu, Q. (2023). A Modified YOLOv8 Detection Network for UAV Aerial Image Recognition. *Drones*, 7(5), 304. <https://doi.org/10.3390/drones7050304>

Lu, D., Xu, L., Zhou, J., Gao, K., Gong, Z., & Zhang, D. (2025). 3D-UMamba: 3D U-Net with state space model for semantic segmentation of multi-source LiDAR point clouds. *International Journal of Applied Earth Observation and Geoinformation*, 136, 104401. <https://doi.org/10.1016/j.jag.2025.104401>

Mohammadi, S., Uhlen, A. K., Lillemo, M., Ergon, Å., & Shafiee, S. (2024). Enhancing phenotyping efficiency in faba bean breeding: integrating UAV imaging and machine learning. *Precision Agriculture*, 25(3), 1502–1528. <https://doi.org/10.1007/s11119-024-10121-4>

Nakamura, T., Kioka, A., Egawa, K., Ishii, T., & Yamada, Y. (2024). Estimating millimeter-scale surface roughness of rock outcrops using drone-flyover structure-from-motion (SfM) photogrammetry by applying machine learning model. *Earth Science Informatics*, 17(3), 2399–2416. <https://doi.org/10.1007/s12145-024-01280-z>

Pan, Y., Li, L., Qin, J., Chen, J., & Gardoni, P. (2024). Unmanned aerial vehicle–human collaboration route planning for intelligent infrastructure inspection. *Computer-Aided Civil and Infrastructure Engineering*, 39(14), 2074–2104. <https://doi.org/10.1111/mice.13176>

Park, M., Kim, H., & Lee, J. (2024). Detection and grading of compost heap using UAV and deep learning. *Korean Journal of Remote Sensing*, 40(1), 33–43. <https://doi.org/10.7780/kjrs.2024.40.1.4>

Peixoto Oliveira, L. T., Oliveira, E. B., Fernandes, V. O., Lima, C. D. A. (2024). *Análise comparativa de métodos para identificação de defeitos em pavimento com uso de imagens de RPA*. In: Anais do 38º Congresso de Pesquisa e Ensino em Transportes. Galoá. <https://proceedings.science/anpet/anpet-2024/trabalhos/analise-comparativa-de-metodos-para-identificacao-de-defeitos-em-pavimento-com-u?lang=pt-br>

Prince, Simon J. D. Understanding deep learning. Cambridge: MIT Press. (2023) <https://udlbook.github.io/udlbook/>

Rahnamayezkavat, P., Wang, D., Chai, J., Moon, S., Rashidi, M., & Wang, X. (2024). Automated pavement marking integrity assessment using a UAV platform – a test case of public parking. *Journal of Asian Architecture and Building Engineering*, 24(3), 1594–1605. <https://doi.org/10.1080/13467581.2024.2329358>

Saydirasulovich, S. N., Mukhiddinov, M., Djuraev, O., Abdusalomov, A., & Cho, Y.-I. (2023). An Improved Wildfire Smoke Detection Based on YOLOv8 and UAV Images. *Sensors*, 23(20), 8374. <https://doi.org/10.3390/s23208374>

Shamta, I., & Demir, B. E. (2024). Development of a deep learning-based surveillance system for forest fire detection and monitoring using UAV. *PLOS ONE*, 19(3), e0299058. <https://doi.org/10.1371/journal.pone.0299058>

Skobalski, J., Sagan, V., Alifu, H., Al Akkad, O., Lopes, F. A., & Grignola, F. (2024). Bridging the gap between crop breeding and GeoAI: Soybean yield prediction from multispectral UAV images with transfer learning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 210, 260–281. <https://doi.org/10.1016/j.isprsjprs.2024.03.015>

Snyder, H. (2019). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104, 333–339. <https://doi.org/10.1016/j.jbusres.2019.07.039>

Soeelman, M. A., Supriyanto, C., & Purwanto. (2023). Deep Learning Model for Unmanned Aerial Vehicle-based Object Detection on Thermal Images. *Revue d'Intelligence Artificielle*, 37(6), 1441–1447. <https://doi.org/10.18280/ria.370608>

Sui, T., Huang, Q., Wu, M., Wu, M., & Zhang, Z. (2024). BiAU-Net: Wildfire burnt area mapping using bi-temporal Sentinel-2 imagery and U-Net with attention mechanism. *International Journal of Applied Earth Observation and Geoinformation*, 132, 104034. <https://doi.org/10.1016/j.jag.2024.104034>

Tiwari, A., Bardhan, S., & Kumar, V. (2022). A Bibliographic Study on Artificial Intelligence Research: Global Panorama and Indian Appearance. *Library Herald*, 60(4), 15–36. <https://doi.org/10.5958/0976-2469.2022.00036.7>

Yigitcanlar, T., David, A., Li, W., Fookes, C., Bibri, S. E., & Ye, X. (2024). Unlocking Artificial Intelligence Adoption in Local Governments: Best Practice Lessons from Real-World Implementations. *Smart Cities*, 7(4), 1576–1625. <https://doi.org/10.3390/smartcities7040064>

Yigitcanlar, T., Senadheera, S., Marasinghe, R., Bibri, S. E., Sanchez, T., Cugurullo, F., & Sieber, R. (2024). Artificial intelligence and the local government: A five-decade scientometric analysis on the evolution, state-of-the-art, and emerging trends. *Cities*, 152, 105151. <https://doi.org/10.1016/j.cities.2024.105151>

Yu, J., Wang, J., & Leblon, B. (2021). Evaluation of Soil Properties, Topographic Metrics, Plant Height, and Unmanned Aerial Vehicle Multispectral Imagery Using Machine Learning Methods to Estimate Canopy Nitrogen Weight in Corn. *Remote Sensing*, 13(16), 3105. <https://doi.org/10.3390/rs13163105>

Yuan, W. (2024). AriAplBud: An Aerial Multi-Growth Stage Apple Flower Bud Dataset for Agricultural Object Detection Benchmarking. *Data*, 9(2), 36. <https://doi.org/10.3390/data9020036>

Zhang, J., Zhou, X., Shen, D., Yu, Q., Yuan, L., & Dong, Y. (2024). Development of Spectral Features for Monitoring Rice Bacterial Leaf Blight Disease Using Broad-Band Remote Sensing Systems. *Phyton-International Journal of Experimental Botany*, 93(4), 745–762. <https://doi.org/10.32604/phyton.2024.049734>

Zhao, Y., Luo, W., Wang, Z., Zhang, G., Liu, J., Li, X., & Wang, Q. (2024). An oil and gas pipeline inspection UAV based on improved YOLOv7. *Measurement and Control*, 57(8), 1068–1086. <https://doi.org/10.1177/00202940241230426>

Biografia do autor principal



Elmo Bispo de Oliveira, natural de Salvador-BA (1992), é Engenheiro Agrimensor e Cartógrafo (2022) pela UFBA, Mestrando em Engenharia Civil no Programa de Pós-Graduação em Engenharia Civil (PPEC/UFBA). É professor temporário no Departamento de Transportes e Geodésia da Escola Politécnica da UFBA. Anteriormente, atuou como Especialista de Nível Superior em Engenharia de Agrimensura e Cartográfica na Fundação Escola Politécnica da Bahia, no contrato FEP/SEFAZ-PMS. Possui experiência como Analista de Geoprocessamento na Produs Soluções em TI no contrato Produs/INEMA e como Coordenador de Aerolevantamento e Georreferenciamento na empresa Terra Exata Soluções em Geotecnologias.



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