

IA-FOGOBIO: INTELIGÊNCIA ARTIFICIAL APLICADA À PREDIÇÃO DE RISCO DE INCÊNDIOS FLORESTAIS NA AMAZÔNIA: UMA REVISÃO SISTEMÁTICA

**IA-FOGOBIO: ARTIFICIAL INTELLIGENCE APPLIED TO FOREST FIRE RISK
PREDICTION IN THE AMAZON: A SYSTEMATIC REVIEW**

Ciências Exatas e da Terra • 04/08/2026

REGISTRO DOI: [10.70773/revistatopicos/785877084](https://doi.org/10.70773/revistatopicos/785877084)

José Pinheiro de Queiroz-Neto¹

Diego Câmara Sales²

Mônica Alves de Vasconcelos³

Luiz Eduardo Sales e Silva⁴

Victor Beltrão Valente Duarte⁵

Deydila Michele Bonfim dos Santos⁶

RESUMO

O sensoriamento remoto aplicado ao monitoramento de incêndios na Amazônia Brasileira tem passado por uma transição paradigmática com a introdução de métodos de inteligência artificial. Este trabalho apresenta uma revisão sistemática da literatura focada no desempenho de algoritmos de aprendizado de máquina (*machine learning*) e aprendizagem profunda (*deep learning*) para a modelagem de sistemas de previsão de incêndio em florestas, com atenção particular à Floresta Amazônica. Foram analisadas arquiteturas de aprendizado por conjunto (*Random Forest* e XGBoost), redes neurais recorrentes (LSTM) e convolucionais (CNN), entre outras possibilidades, correlacionando-as com variáveis geoespaciais de clima, topografia, uso do solo, entre outras. Os resultados demonstram que algoritmos como o XGBoost superam métodos tradicionais em termos de erro residual em bases de dados de alta dimensionalidade. Identificou-se que a integração de redes LSTM permite a modelagem de dependências temporais críticas para a previsão de risco sazonal, enquanto técnicas de análise espaço-temporal revelam a persistência de clusters de fogo em eixos antrópicos. A revisão destaca que a eficiência dos sistemas de monitoramento atuais reside na escolha adequada das variáveis a serem utilizadas no sistema, e da capacidade dessas tecnologias de processar grandes volumes de dados com alta acurácia, reduzindo falsos positivos e permitindo o mapeamento preventivo de áreas críticas no bioma amazônico.

Palavras-chave: Predição de incêndio; Inteligência Artificial; Floresta Amazônica.

ABSTRACT

Remote sensing applied to fire monitoring in the Brazilian Amazon has undergone a paradigmatic transition with the introduction of

artificial intelligence methods. This paper presents a systematic literature review focused on the performance of machine learning and deep learning algorithms for fire occurrence modeling. Ensemble learning architecture (Random Forest and XGBoost), recurrent neural networks (LSTM), and convolutional networks (CNN) were analyzed, correlating them with geospatial variables of climate, topography, and land use. The results demonstrate that algorithms such as XGBoost outperform traditional methods in terms of residual error in high-dimensional datasets. It was identified that the integration of LSTM networks allows for the modeling of critical temporal dependencies for seasonal risk prediction, while spatio-temporal analysis techniques reveal the persistence of fire clusters in anthropogenic axes. The review highlights that the efficiency of current monitoring systems lies in appropriate selection of variables to be used in the system, and the capacity of these technologies to process large volumes of orbital sensor data with high accuracy, reducing false positives and enabling the preventive mapping of critical areas in the Amazon biome.

Keywords: Fire risk prediction; Artificial Intelligence; Amazon Rainforest.

1. INTRODUÇÃO

A Amazônia brasileira tem enfrentado uma pressão crescente decorrente de incêndios florestais severos, fenômeno que ameaça a integridade da biodiversidade e o cumprimento de compromissos climáticos internacionais (Artaxo, 2020). Em 2024 um dos anos mais críticos, com cerca de 30 milhões de hectares queimados, área queimada superou a média histórica em 117%, com destaque para o Pará, Amazonas e Mato Grosso, que concentraram a maior parte dos focos (MapBiomas, 2025; INPE, 2024a).

A distribuição das ocorrências de fogo na Amazônia revela um padrão marcado pela maior concentração de ignições no chamado “arco do desmatamento”, localizado entre os limites leste e sul da região. Contudo, surgem indícios de uma nova frente de pressão voltada à conversão do uso do solo no nordeste amazônico, fenômeno que parece estar associado ao crescimento das ocorrências de fogo em áreas de savana dentro da Amazônia (Santana, 2022). Na Amazônia, o início dos incêndios (ignição) está fortemente ligado à presença humana (fatores antrópicos) e à fragmentação da floresta (Silvestrini, 2008).

Em 2025 teve início o projeto “IA-FogoBio: Inteligência Artificial para Predição de Risco e Avaliação de Impacto de Eventos de Fogo na Biodiversidade Amazônica”, aprovado na Chamada Pública “Entenda o Desafio IA, Natureza & Clima”, do Instituto Clima e Sociedade (iCS), em parceria com a Google.org, coordenado pelo Instituto Federal de Educação, Ciência e Tecnologia do Amazonas (IFAM), em parceria com o Centro Gestor e Operacional do Sistema de Proteção da Amazônia (CENSIPAM), com execução da Fundação de Apoio ao Ensino, Pesquisa, Extensão e Interiorização do IFAM (FAEPI).

O CENSIPAM atua como órgão central de monitoramento, fornecendo dados de satélites para apoiar brigadas do Centro Nacional de Prevenção e Combate aos Incêndios Florestais (PREVFOGO), do Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio) e Corpos de Bombeiros. Observa-se que o modelo vigente é predominantemente reativo, pautado no combate pós-ignição, o que limita o potencial de ações preventivas e culmina em mobilizações tardias ante a dinâmica acelerada das frentes de fogo (Schmidt *et al.*, 2018).

O IFAM, pela sua expertise em tecnologias e proximidade com a realidade amazônica, tem potencial estratégico e tecnológicos para desenvolver soluções complementares às existentes atualmente. O grande desafio é a transição para de modelo reativo para um modelo proativo e preditivo, capaz de antecipar eventos de fogo com 7-14 dias de antecedência, considerando variáveis climáticas, antrópicas e de uso do solo. A precisão das análises é limitada por problemas como superestimação da área queimada e ausência de classificação automática das causas (desmatamento, manejo agrícola ou incêndio natural).

O Projeto IA-FogoBio visa, ainda, criar um sistema web independente, baseado em inteligência artificial, focado na análise de impactos do fogo em biomas e tipos de solo amazônicos, estabelecendo plataforma autônoma especializada em avaliação ecológica e estratégias de prevenção baseadas em características biogeofísicas. A estratégia centra-se na compreensão profunda de como diferentes biomas e solos respondem ao fogo, gerando conhecimento científico aplicado que pode auxiliar análises do Painel do Fogo e outros sistemas, mas operando de forma completamente independente.

Esta Revisão Sistemática da Literatura (RSL) se justifica como base conceitual e técnico-científica inicial para o desenvolvimento do Projeto IA-FogoBio, visando identificar, sintetizar e apresentar as pesquisas atuais sobre o uso da Inteligência Artificial para predição de risco e avaliação de impacto de eventos de fogo, em particular na Amazônia. A contribuição desta revisão para o conhecimento existente é significativa, pois há uma escassez de estudos de revisão focados especificamente neste tema, em particular na Amazônia. Embora existam revisões que abrangem sistemas de

monitoramento de incêndios de forma geral, poucas se concentram no uso de inteligência artificial e na Amazônia. Para abordar essa questão, a presente Revisão Sistemática RSL propõe três Questões de Pesquisa (QPs) que a orientam:

QP1: Como são desenvolvidos os sistemas de prevenção ou predição de incêndios na Amazonia?

QP2: Quais métodos e tecnologias principais são utilizadas e quais resultados obtidos?

QP3: Quais variáveis devem ser levadas em consideração para um sistema inteligente de predição de risco de incêndio na Amazonia?

Além disto, definiu como objetivos específicos: 1) analisar os sistemas inteligentes propostos ou em uso para o monitoramento e predição de risco de incêndio na Amazônia; 2) definir os tipos de dados utilizáveis para um sistema inteligente de predição de incêndio na Amazônia.

O escopo da RSL na Amazônia, embora existam importantes biomas com problemas de queimada, como o Cerrado, Mata Atlântica e Pantanal, se justifica em função de seu uso em projeto com escopo na Amazônia. Os resultados desta revisão irão orientar a pesquisa em andamento no âmbito do projeto IA-FogoBio. Além disso, os resultados desta revisão servem como base científica para o desenvolvimento de outros projetos nesta área.

1.1. Importância de Prevenção de Incêndio em Florestas

A prevenção de incêndios em florestas é fundamental para garantir a proteção da biodiversidade, a manutenção dos serviços

ecossistêmicos e a segurança das comunidades humanas que dependem diretamente desses ambientes. Os incêndios florestais, sejam de origem natural ou provocados por atividades humanas, podem causar danos irreversíveis ao equilíbrio ecológico, comprometendo espécies vegetais e animais, além de afetar o clima.

Entre os principais motivos que tornam a prevenção essencial, destacam-se:

- a. Proteção da biodiversidade: Florestas abrigam milhares de espécies únicas. O fogo descontrolado pode levar à extinção de animais e plantas, reduzindo a riqueza biológica;
- b. Manutenção do equilíbrio climático: As florestas atuam como reguladoras do clima, absorvendo dióxido de carbono. Incêndios liberam grandes quantidades de gases de efeito estufa, intensificando o aquecimento global;
- c. Segurança das populações locais: Comunidades que vivem próximas às áreas florestais sofrem com perdas materiais, riscos à saúde e impactos econômicos quando ocorrem incêndios;
- d. Preservação dos recursos naturais: O fogo compromete a qualidade do solo, a disponibilidade de água e a regeneração da vegetação, afetando atividades como agricultura e pesca;
- e. Redução de custos e danos: Investir em prevenção é mais eficiente e menos oneroso do que mobilizar recursos para combater incêndios já em andamento.

A prevenção envolve ações como educação ambiental, fiscalização contra queimadas ilegais, monitoramento por satélite, criação de brigadas comunitárias e desenvolvimento de tecnologias preditivas. Além disso, políticas públicas integradas e a cooperação internacional são indispensáveis para enfrentar o desafio em regiões como a Amazônia, onde os incêndios têm aumentado nos últimos anos.

1.2. Sistemas de Prevenção e Acompanhamento de Incêndios em Florestas no Brasil

Um sistema de prevenção de incêndios florestais é um conjunto de estratégias e ações para evitar que o fogo comece e se espalhe, envolvendo educação ambiental, manejo da vegetação, monitoramento de umidade e uso de tecnologia para detectar focos precocemente, focando em ações a curto e longo prazo para proteger a floresta e reduzir riscos. Sistemas de monitoramento contínuo são fundamentais para detectar focos de incêndio precocemente. Os principais instrumentos incluem:

- a. Sensoriamento remoto: satélites e drones com sensores térmicos e ópticos;
- b. Torres de vigilância e câmeras inteligentes: identificam fumaça ou chamas a grandes distâncias;
- c. Inteligência Artificial (IA): algoritmos que analisam dados climáticos e imagens para prever áreas de risco;
- d. Centros de controle integrados: coordenação nacional de ações, como o Prevfogo/IBAMA e o Painel do Fogo (Ibama, 2024a).

No Brasil, alguns sistemas de monitoramento se destacam, são estes:

- a. Prevfogo/IBAMA: programa nacional de prevenção e combate, coordenando brigadas e campanhas educativas (Ibama, 2024a);
- b. Sisfogo: sistema em desenvolvimento para integrar dados sobre queimadas autorizadas e indicadores de políticas públicas (Ibama, 2024b);
- c. Painel do Fogo (MapBiomas): plataforma pública que reúne dados históricos e atuais sobre áreas queimadas desde 1985, fortalecendo a transparência e a gestão (Censipam, 2024);
- d. Programa Queimadas (INPE/CPTEC): detecta focos de calor em tempo real via satélite, com mapas e relatórios diários (INPE, 2024a);
- e. BDQueimadas (INPE): banco de dados histórico de queimadas desde 1998 (INPE, 2024a);
- f. SafeForest: projeto acadêmico brasileiro que utiliza sensores e algoritmos para identificar riscos e acionar respostas rápidas (INPE, 2024b).

Brasil, iniciativas como o Prevfogo, o Painel do Fogo e o Programa Queimadas do Instituto Nacional de Pesquisas Espaciais (INPE) demonstram avanços significativos, mas ainda enfrentam desafios estruturais e climáticos. Em escala global, o uso de satélites, IoT e inteligência artificial aponta para um futuro em que a integração

tecnológica e institucional será decisiva para reduzir os impactos dos incêndios e garantir a sustentabilidade dos ecossistemas.

1.3. Trabalhos Relacionados

Tong Li *et al.* (2023) disponibilizam um estudo que mapeia como a ciência dos incêndios florestais evoluiu globalmente nas últimas décadas. O estudo analisa a produção científica internacional sobre incêndios florestais nos últimos 20 anos, revelando um crescimento médio anual de 22,45% no número de publicações.

Através de análises estatísticas da base *Web of Science*, os autores concluem que a ciência do fogo está migrando de estudos locais e isolados para uma abordagem de "fusão de disciplinas", onde observações espaciais (satélites), simulações computacionais precisas e o estudo de mecanismos biológicos se fundem para entender os efeitos dos incêndios em escalas temporais e espaciais cada vez maiores.

Amoah-Nuamah *et al.* (2025) analisam a transição para a "Saúde Florestal 4.0", e destacam como a Inteligência Artificial supera as limitações dos métodos convencionais de monitoramento. Os autores demonstram que o uso de Inteligência Artificial cria sistemas que otimizam a previsão de incêndios e a quantificação de biomassa e carbono. Os autores sugerem que a fusão de dados multiespectrais com modelos de decisão inteligentes é o caminho fundamental para garantir a resiliência e a sustentabilidade dos ecossistemas florestais globais diante das ameaças das mudanças climáticas.

A literatura científica recente apresenta importantes estudos secundários que buscam sintetizar o conhecimento sobre a

dinâmica do fogo na região amazônica. Oliveira e Souza (2022), por exemplo, realizaram uma revisão sistemática focada na evolução das tecnologias de sensoriamento remoto, destacando como o aprimoramento dos sensores orbitais permitiu uma detecção mais precisa de focos de calor. No entanto, o foco dessa análise concentrou-se na capacidade técnica de monitoramento, deixando uma lacuna sobre como esses dados são integrados à logística de resposta das brigadas em campo.

Complementarmente, estudos como o de Libonati *et al.* (2020) revisaram a performance de diferentes produtos de mapeamento de cicatrizes de fogo, evidenciando as disparidades entre dados de focos ativos e a área efetivamente queimada. Essa distinção é crucial, pois a subestimação da extensão dos incêndios pode levar a um planejamento ineficaz das políticas de manejo. Apesar da relevância desse mapeamento técnico, ainda são escassas as revisões que utilizem a série histórica longa do MapBiomas para correlacionar o aumento das cicatrizes de fogo com a estrutura reativa dos órgãos de controle.

Sob a perspectiva dos impactos sistêmicos, a produção acadêmica de Artaxo (2020) oferece uma síntese crítica sobre os riscos do ponto de não retorno (*tipping point*) da Amazônia, onde o fogo atua como um acelerador da degradação florestal. Embora essas revisões de perspectiva climática fundamentem a urgência do tema, elas geralmente abordam o fogo como uma variável ambiental externa, sem detalhar o papel dos sistemas de proteção, como o CENSIPAM e o PREVFOGO, na mitigação direta desses eventos através de ações preventivas.


Por fim, no campo da gestão de políticas públicas, Morello *et al.* (2020) revisaram a eficácia das estratégias de combate aos incêndios no Brasil, apontando que o investimento em supressão pós-ignição é financeiramente menos eficiente que o Manejo Integrado do Fogo (MIF). Este trabalho identifica-se com essa linha de raciocínio, mas busca preencher uma lacuna específica: a sistematização da literatura que conecta o desempenho operacional das brigadas com os dados geoespaciais de 2024. Assim, esta RSL diferencia-se ao propor uma análise da transição necessária de um sistema de monitoramento reativo para um modelo de inteligência preventiva.

Esta RSL diferencia-se das demais ao focar na transição do modelo reativo para o preventivo, utilizando sistemas baseados em inteligência artificial e dados de entrada relevantes para o Bioma amazônico.

2. METODOLOGIA

Visando analisar, avaliar e sintetizar rigorosamente os estudos relacionados para responder às Questões de Pesquisa, seguimos as diretrizes do modelo de fluxograma PRISMA (Page, 2021), que ilustra todo o processo de busca e seleção dos artigos nas bases de dados (Figura 1).

Figura 1. Etapas da Revisão Sistemática de Literatura (RSL)



Fonte: Elaborado pelos autores (2026)

O diagrama da Figura 1 é resultado de um protocolo de revisão, descrevendo o processo de busca na literatura, critérios de elegibilidade, a extração de dados e os procedimentos de análise de dados.

2.1. Processo de Pesquisa Bibliográfica

As bases de dados eletrônicas utilizadas para a pesquisa bibliográfica incluíram: (1) *Web Of Science* (WoS), (2) *Scopus* (Elsevier), (3) *SciELO* (*Scientific Electronic Library Online*), (4) *Science Direct* e (5) *Springer Nature Link*. Com base em parâmetros de busca relacionadas à predição de incêndio utilizando inteligência artificial. Foram selecionadas publicações referentes às áreas: Ciência da Computação, Ecologia, Geociências e Meio Ambiente. A busca foi realizada em Língua Portuguesa e Inglesa em todas as bases conforme o Quadro 1.

Para facilitar a busca nas bases de dados, este estudo examinou artigos revisados por pares publicados nos últimos cinco anos (de 2020 até fevereiro de 2026). A consulta e o acesso a todos os artigos ocorreram durante o período de novembro de 2025 a fevereiro de 2026.

Para a análise foram considerados os títulos, palavras-chaves e textos principais, previamente selecionados para verificar quais publicações se enquadram na área de predição ou monitoramento de incêndios em floresta utilizando inteligência artificial.

Quadro 1. Bases de dados utilizadas para consulta

Bases de Dados/Motor de Busca	Parâmetros de busca
<i>Web of Science</i>	Pesquisa em inglês: ("forest fire*" OR "wildfire*" OR "biomass burning") AND ("Amazon" OR "Amazonia" OR "Amazônia" OR "tropical forest*" OR "rainforest*") AND ("risk prediction" OR "risk modeling" OR "fire simulation" OR "remote sensing" OR "satellite data") AND ("artificial intelligence") Pesquisa em português: ("incêndio florestal" OR "incêndio florestal" OR "queima de biomassa") AND ("Amazônia" OR "floresta tropical" OR "floresta pluvial") AND ("previsão de risco" OR "modelagem de risco" OR "simulação de incêndio" OR "sensoriamento remoto" OR "dados de satélite") AND ("inteligência artificial")
<i>Scopus (Elsevier)</i>	
<i>Scielo</i>	
<i>Science Direct</i>	
<i>Springer Nature Link</i>	

Fonte: Elaborado pelos autores (2026)

2.2. Processo de Pesquisa Bibliográfica

Conforme ilustrado na Figura 1, utilizando os descritores de pesquisa por palavras-chave, foram identificados 1.641 artigos, sendo 382 provenientes da *Web of Science*, 371 da *Scopus (Elsevier)*, 70 da *Scielo*, 636 da *Science Direct* e 182 da *Springer Nature Link*. A busca com descritores em português só foi efetiva na base *Scielo*, ainda assim com poucos resultados. A seleção dos documentos teve como critérios de inclusão e exclusão os argumentos listados conforme Quadro 2 do protocolo de Revisão Sistemática da Literatura.

Os seguintes artigos foram excluídos com base em seus títulos e resumos: (1) estudos irrelevantes ao tema da pesquisa (n=1140). Por exemplo, primeiro, o estudo não está relacionado à predição ou mesmo avaliação de risco de incêndio em região de floresta; segundo, estudos publicados a 6 ou mais anos (n=434); terceiro, artigos científicos duplicados (n=10); quarto, artigos que não eram publicações em periódicos científicos ou artigos pagos (05); quinto, trata-se de uma revisão da literatura, discussão e/ou artigo de opinião (n=02); e sexto, artigos cujos resultados não tinham aderência ao tema da pesquisa (n=03).

Quadro 2. Critérios de inclusão e exclusão para análise.

Fase	Critérios de inclusão	Critérios de exclusão
Seleção e identificação dos estudos	Artigos científicos completos	Estudos irrelevantes ao tema da pesquisa
	Disponíveis na base de dados com acesso livre	Artigos científicos duplicados
	Publicado nos últimos 5 anos	Publicado a 6 ou mais anos
	Publicado em português, inglês ou espanhol	Trata-se de uma revisão da literatura de

		discussão e/ou artigo de opinião
	Estudos que abordem a predição ou avaliação de incêndio em floresta utilizando inteligência artificial	Artigos cujos resultados não tinham aderência ao tema da pesquisa
	Descritores no título, resumo ou palavra-chave	Artigos que não eram publicações em periódicos científicos ou artigos pagos

Fonte: Elaborado pelos autores (2026)

Excepcionalmente, e por se tratar de marcos importantes, três artigos foram aceitos, ainda que não atendessem ao segundo critério. Os critérios de inclusão exigiram que os artigos estivessem em inglês, português ou espanhol. Como resultado, 45 artigos foram revisados de forma detalhada no presente estudo.

2.3. Procedimentos de Análise de Dados

Visando melhorar a organização e efetividade dos dados obtidos, a literatura foi revisada cuidadosamente para extrair, codificar e categorizar de forma sistemática cada trabalho, inclusive com o uso, quando necessário, de procedimentos da técnica Análise de Conteúdo (Bardin, 2016). Os trabalhos incluídos foram codificados e revisados por pelo menos dois dos autores.

Tabela 1. Estrutura de codificação

Tecnologias/ Região	Trabalhos
------------------------	-----------

<i>Random Forest</i> (RF)	Torres <i>et al.</i> (2020); Santana Neto <i>et al.</i> (2022); Rubí <i>et al.</i> (2022); Anandaram <i>et al.</i> (2023); Freitas <i>et al.</i> (2024); Vergara <i>et al.</i> (2025)
<i>Gradient Boosting</i> (XGBoost)	Caneppele <i>et al.</i> (2023); Tran <i>et al.</i> (2024); Mishra <i>et al.</i> (2024); Karurung <i>et al.</i> (2025)
Redes Neurais recorrentes (LSTM)	Abid <i>et al.</i> (2021); Yin <i>et al.</i> (2025); Gao <i>et al.</i> (2026); Xu <i>et al.</i> (2026)
Redes Neurais Convolucionais (CNN)	Ali Khan (2022); Seydi <i>et al.</i> (2022); Jiang <i>et al.</i> (2024); Ejaz e Choudhury (2025); Xu <i>et al.</i> (2025); Pan <i>et al.</i> (2026).
Região Amazônica/Brasil	Maeda <i>et al.</i> (2011); Diniz <i>et al.</i> (2015); Fanin e Werf (2015); Silva Junior (2018); Torres <i>et al.</i> (2020); Silva <i>et al.</i> (2021); Lemos e Cunha (2021); Arantes Silva (2021); Luz <i>et al.</i> (2022); Santana (2022); Pereira <i>et al.</i> (2022); Rubí <i>et al.</i> (2022); Ferreira <i>et al.</i> (2023); Valente e Laurini (2023); Juvanhil <i>et al.</i> (2023); Silva <i>et al.</i> (2024); Rahmani (2025); Freitas (2024); Vergara <i>et al.</i> (2025); Lemos <i>et al.</i> (2025); Soundararajan <i>et al.</i> (2026)

Fonte: Elaborado pelos autores (2026)

A estrutura de codificação para o uso da inteligência artificial para predição de risco de incêndio na Amazônia foi organizada com base nas principais tecnologias de IA utilizadas, sejam de aprendizagem de máquina ou aprendizagem profunda: *Random Forest* (RF), *Gradient Boosting* (XGBoost), Redes Neurais Recorrentes (LSTM), e Redes Neurais Convolucionais (CNN), e com base na região de teste e resultado dos sistemas desenvolvidos, com atenção em particular para a região Amazônica (Tabela 1).

Embora a predição de incêndios florestais seja um tema essencial e amplamente explorado em diferentes partes do mundo, sua investigação no contexto da região Amazônica ainda é bastante limitada. Em outras regiões existem vários trabalhos, mas que de certa maneira se repetem em métodos e resultados. Portanto, presumimos que essa quantidade de artigos de pesquisa seja suficiente para oferecer uma análise exploratória sobre o uso da inteligência artificial na predição de incêndios florestais, em particular na região Amazônica.

3. FUNDAMENTAÇÃO TEÓRICA

Zhai *et al.* (2025) oferece uma revisão abrangente sobre o ciclo de vida dos incêndios florestais, estruturando as inovações tecnológicas em três pilares: monitoramento, previsão de propagação e técnicas de supressão. Os autores destacam a transição dos métodos tradicionais para sistemas inteligentes baseados em IA, Big Data e Internet das Coisas (IoT), enfatizando a importância da integração de dados multiespectrais de satélites com redes de sensores terrestres para uma detecção precoce.

Esta revisão vai mais além e se preocupa com a predição do incêndio, ou seja, antes que este tenha se iniciado, e analisou um total de 42 estudos realizados em diferentes países, no período de 2020 a 2026, e 03 estudos anteriores a 2020. Embora alguns artigos tenham utilizado mais de um método de IA para fins de comparação, ou ainda a integração de dois ou mais algoritmos, iremos considerar o resultado principal ou mais relevante, quando forem estes os casos, de acordo com o estabelecido na Tabela 1.

3.1. Sistemas Utilizando Random Forest (RF)

O algoritmo *Random Forest* (RF), fundamentado no aprendizado conjunto (*ensemble learning*) e na técnica de *Bagging*, consolidou-se como a ferramenta mais robusta para a predição de riscos de incêndio na literatura analisada (Breiman, 2001; Freitas, 2024). Sua capacidade de mitigar o sobreajuste (*overfitting*) e processar múltiplas variáveis independentes permite identificar zonas críticas com alta precisão estatística (Freitas *et al.*, 2022; Torres *et al.*, 2020).

A aplicação do RF no contexto brasileiro demonstra uma evolução significativa na precisão cartográfica. Torres *et al.* (2020), ao processar 65 variáveis ambientais para o estado de Minas Gerais, alcançaram uma acurácia global de 82%, confirmando a eficácia do modelo em escalas regionais. Em biomas específicos, como o Cerrado, o RF atingiu 89% de acurácia, superando arquiteturas de redes neurais profundas (Rubí *et al.*, 2022). Na Amazônia, o desempenho do algoritmo na área de Proteção Ambiental (APA) Triunfo do Xingu revelou que 39% da unidade apresenta suscetibilidade alta ou muito alta, validando o uso da IA como estratégia para o planejamento de ações de comando e controle (Freitas, 2024).

Internacionalmente, os sistemas baseados em RF também apresentam resultados superiores a métodos estatísticos clássicos e outros algoritmos de aprendizagem de máquina. No norte de Portugal, o RF obteve a melhor acurácia (74%) e maior capacidade de distinção de áreas de baixo risco em comparação à Regressão Linear Múltipla (Santana Neto *et al.*, 2022). No Departamento de Amazonas, Peru, o RF apresentou o melhor desempenho preditivo (AUC de 0,91), identificando que fatores antrópicos, como a facilidade de acesso via estradas, explicam 84% das ignições na região (Vergara *et al.*, 2025). Estudos na Índia reforçam que o RF, quando integrado à

análise geoestatística, supera algoritmos como XGBoost e *Support-Vector Machine* (SVM) na identificação de zonas que exigem intervenção imediata (Mishra *et al.*, 2024).

A predominância do RF nos sistemas de monitoramento deve-se à sua versatilidade em lidar com dados de sensoriamento remoto multitemporais e variáveis socioambientais complexas, fornecendo subsídios científicos assertivos para a gestão de desastres ambientais. Isto se deve, principalmente, à sua arquitetura de árvores de decisão independentes, onde a classificação final é obtida por meio de votação majoritária, o que reduz a variância do modelo em biomas heterogêneos como a Amazônia.

Apesar da hegemonia do Random Forest em dados tabulares e geoestatísticos, pesquisas recentes têm explorado outras arquiteturas para o processamento de imagens de satélite multitemporais, como será discutido em outras seções.

3.2. Sistemas Utilizando Extreme Gradient Boosting (XGBoost)

O algoritmo XGBoost consolidou-se na última década como uma das implementações mais eficientes do método de *Gradient Boosting*, sendo projetado para maximizar tanto a precisão preditiva quanto a escalabilidade computacional (Caneppele *et al.*, 2023). Diferente do RF, que utiliza o aprendizado paralelo, o XGBoost fundamenta-se em um processo sequencial e aditivo: cada nova árvore de decisão é construída com o objetivo específico de corrigir os resíduos (erros) das árvores anteriores. Esse refinamento contínuo, guiado por uma função de perda otimizada pelo gradiente, permite que o modelo evolua de um "aprendiz fraco" para um preditor de alta performance.

A superioridade do XGBoost em cenários de monitoramento ambiental, como o bioma amazônico, reside em sua arquitetura robusta contra o sobreajuste (*overfitting*). Conforme destacado por Caneppele et al. (2023), o algoritmo incorpora sistemas de regularização L1 (*Lasso*) e L2 (*Ridge*), além de possuir uma capacidade nativa de lidar com dados esparsos e valores ausentes — um desafio constante em séries temporais de sensoriamento remoto sujeitas a ruídos atmosféricos e cobertura de nuvens.

Na literatura internacional, o desempenho do XGBoost tem superado benchmarks tradicionais em diversas escalas geográficas. No Sudeste Asiático (Indonésia), o XGBoost demonstrou ser o algoritmo mais eficaz entre nove modelos testados, alcançando uma Área sob a Curva Característica de Operação (AUC) entre 0,71 e 0,95. O estudo de Karurung et al. (2025) enfatiza que o diferencial do algoritmo foi sua precisão em capturar a variabilidade entre as estações seca e chuvosa, integrando variáveis como umidade do solo e presença de turfeiras para antecipar focos de calor com maior antecedência.

Um avanço crítico na utilização desta tecnologia é a superação do paradigma da "caixa-preta". No Havaí, Tran et al. (2024) utilizaram o conceito de IA Explicável (XAI) e integraram o XGBoost ao método SHAP (*SHapley Additive exPlanations*), permitindo que gestores públicos compreendam exatamente quais variáveis (como proximidade de estradas ou déficit hídrico) estão pesando mais no risco de cada região. Essa transparência elevou a acurácia para patamares acima de 0,93, fornecendo subsídios auditáveis para políticas de prevenção.

A pesquisa de Mishra *et al.* (2024) reforça a versatilidade do XGBoost ao combiná-lo com análise espacial geoestatística. Os resultados indicaram que, ao processar um vasto espectro de condicionantes (climáticos, topográficos e antrópicos), o XGBoost identificou zonas críticas com rigor superior ao RF, consolidando-se como pilar essencial para o manejo florestal economicamente viável.

No contexto brasileiro, o uso do XGBoost tem sido apontado como estratégico para regiões sob forte pressão de desmatamento. Ao integrar dados multitemporais de sensores como o MODIS (*Moderate Resolution Imaging Spectroradiometer*) e variáveis de uso do solo, o modelo consegue capturar a não-linearidade dos processos de degradação antrópica (Caneppele *et al.*, 2023). Portanto, a eficiência computacional do XGBoost, aliada à sua capacidade de processamento paralelo em nível de sistema, o torna a ferramenta ideal para sistemas de alerta em tempo real que demandam alta precisão em escala regional.

3.3. Sistemas Utilizando Redes Neurais Recorrentes (LSTM)

As redes *Long Short-Term Memory* (LSTM) representam uma evolução das Redes Neurais Recorrentes (RNN), projetadas para aprender dependências de longo prazo em séries temporais complexas (Yin *et al.*, 2025). Sua arquitetura baseada em "portões" (*gates*) de entrada, saída e esquecimento permite que o modelo retenha informações de eventos passados, como meses de seca extrema ou acúmulo de biomassa, que influenciam a inflamabilidade presente, superando o problema do gradiente dissipante comum em redes neurais convencionais (Abid *et al.*, 2021; Yin *et al.*, 2025).

A aplicação da LSTM na predição de incêndios florestais tem se destacado pela capacidade de modelar trajetórias de risco ao longo de décadas. Yin *et al.* (2025) utilizaram essa arquitetura para mapear um século de dados na China, demonstrando como a integração de reconstruções meteorológicas históricas e pressão antrópica revela a evolução da vulnerabilidade florestal frente às mudanças climáticas. No contexto do diagnóstico de risco, Gao *et al.* (2026) propuseram um framework que integra fatores estáticos ("estado") e dinâmicos ("tendência"), comprovando que a inclusão de indicadores de tendência temporal via LSTM melhora significativamente a precisão ao capturar estresses hídricos acumulados.

As tendências mais recentes apontam para a transição de métodos estatísticos tradicionais para modelos híbridos e multimodais (Ejaz; Choudhury, 2025). A abordagem de ponta de Xu *et al.* (2026) utiliza Deep Learning Multimodal para fundir dados numéricos/temporais (via LSTMs) com imagens orbitais (utilizando CNN). Esse processamento paralelo de dados estruturados e não estruturados alcançou performance superior a 94% (AUC), superando modelos isolados de RF e XGBoost.

As revisões sistemáticas (Abid *et al.*, 2021; Ejaz; Choudhury, 2025) reforçam que, embora o RF e o SVM sejam precisos para variáveis numéricas puras, as redes LSTM são superiores na análise de séries extensas e dados de sensores em tempo real, mantendo a consistência de dados e sendo cruciais para biomas como a Amazônia, onde o histórico de degradação dita a severidade das queimadas atuais.

Embora com resultados de acurácia inferiores, a capacidade das redes LSTM de filtrar informações históricas relevantes consolida

estas arquiteturas como ferramentas de alta resolução espacial e temporal, estabelecendo um novo padrão para o monitoramento preventivo e a antecipação de desastres ambientais em escala regional.

3.4. Sistemas Utilizando Redes Neurais Convolucionais (CNN)

As Redes Neurais Convolucionais (CNN) constituem uma classe de *Deep Learning* projetada para o processamento de dados em grelha, sendo ideais para a análise de imagens orbitais e vídeos de monitoramento (Khan *et al.*, 2022). O diferencial desta arquitetura reside nas camadas de convolução, que atuam como filtros automáticos capazes de extrair características espaciais, tais como bordas de desmatamento, texturas de fumaça e padrões térmicos, e isto sem a necessidade de engenharia de atributos manual (Khan *et al.*, 2022; Xu *et al.*, 2025).

Na literatura recente, as CNNs têm sido aplicadas em duas frentes principais. A primeira é na Detecção Ativa e Visão Computacional. O sistema *DeepFire*, proposto por Khan *et al.* (2022), utiliza *Deep Transfer Learning* para alcançar 95% de acurácia na identificação visual de focos em tempo real, mostrando-se eficiente inclusive para dispositivos móveis e drones.

Complementarmente, o *framework Fire-Net* (Seydi *et al.*, 2022) foca na redução de falsos positivos em imagens Landsat-8, utilizando mecanismos de atenção para distinguir incêndios de superfícies reflexivas ou nuvens, superando os algoritmos tradicionais da *National Aeronautics and Space Administration* (NASA) com precisão acima de 95%.

A segunda é no Mapeamento de Risco e Modelagem Híbrida. Além da detecção imediata, as CNNs demonstram superioridade na identificação de padrões não lineares para o zoneamento de risco. Em Guangdong, China, modelos baseados em CNN superaram algoritmos como RF e XGBoost, atingindo uma AUC de 0,962 ao integrar variáveis meteorológicas e Índice de Vegetação por Diferença Normalizada (NDVI) (Jiang *et al.*, 2024). A vanguarda da técnica, entretanto, reside em sistemas híbridos: Pan *et al.* (2026) propuseram um framework que utiliza saídas de modelos climáticos globais como entrada para CNNs, permitindo previsões sazonais com um mês de antecedência e conectando a probabilidade de risco a protocolos de ação emergencial para brigadistas.

Estudos apontam que a transição para arquiteturas convolucionais permite que os sistemas de monitoramento alcancem invariância espacial e alta fidelidade na detecção (Xu *et al.*, 2025). Essa capacidade de "visão computacional" é um requisito essencial para superar as limitações de modelos puramente estatísticos frente à complexidade das mudanças climáticas globais.

3.5. Sistemas no Contexto da Região Amazônica e Brasil

A implementação de modelos de Inteligência Artificial para o monitoramento do bioma amazônico exige uma abordagem que transcenda os índices meteorológicos globais, focando nas particularidades da dinâmica de uso do solo tropical. Estudos aplicados na região (Caneppele *et al.*, 2023; Freitas, 2024; Lemos *et al.*, 2025) demonstram que a eficácia da IA se encontra intrinsecamente ligada à integração de variáveis como o histórico de fogo, a fragmentação florestal e a proximidade de infraestruturas antrópicas, como rodovias e frentes de desmatamento.

3.5.1. Evolução Histórica e Marcos de Monitoramento

A base da modelagem preditiva no Brasil consolidou-se com estudos pioneiros que integraram sensoriamento remoto e inteligência computacional. Maeda *et al.* (2009) demonstraram a viabilidade de utilizar Redes Neurais Artificiais (RNA) alimentadas pelo sensor MODIS, estabelecendo que padrões espectrais de vegetação e temperatura de superfície possuem valor preditivo superior a métodos de interpolação meteorológica convencional. Posteriormente, Maeda *et al.* (2011) aprimoraram essa técnica ao introduzir a Análise de Vetor de Mudança (CVA), permitindo a detecção espacialmente explícita do estresse hídrico pré-fogo, servindo de fundamento para os atuais modelos de *Deep Learning*.

No campo da fiscalização tática, o sistema DETER-B (INPE) representa um marco na governança ambiental brasileira (Diniz *et al.*, 2015). A transição para o sensor AWiFS (56m de resolução) permitiu identificar polígonos de desmatamento a partir de 3 hectares, combatendo a estratégia de infratores que realizam cortes pequenos para evitar a detecção satelital. Embora o DETER-B atue como inteligência tática sem o uso direto de IA, seus dados fornecem a base de validação para os modelos preditivos contemporâneos.

3.5.2. Fragmentação, Efeito de Borda e Dinâmica Antrópica

A estrutura da floresta, e não somente o clima, é um determinante crítico da ignição. Silva Junior *et al.* (2018) demonstram que a fragmentação florestal potencializa a vulnerabilidade ao fogo através do "efeito de borda": áreas próximas às bordas dos fragmentos tornam-se mais secas e acumulam biomassa morta, criando o

combustível ideal. A pesquisa revelou que a maioria dos focos ocorre a uma distância de até 1,5 km das bordas, onde o microclima é alterado.

Essa dinâmica é amplificada pela atividade humana, onde o fogo é utilizado como ferramenta de manejo. Fanin e Van Der Werf (2015) alertam para uma desconexão parcial entre taxas de desmatamento e incêndios, sugerindo que a maior parte da queima ocorre em áreas já degradadas ou pastagens. No entanto, o fogo associado ao desmatamento recente (corte raso) permanece como a ferramenta primária para remoção de biomassa, disparando as emissões de gases de efeito estufa (Silva *et al.*, 2021). Valente e Laurini (2023) reforçam que o fenômeno não é aleatório, apresentando uma "memória espacial" concentrada no Arco do Desmatamento, onde a probabilidade de novos focos aumenta em áreas próximas a ocorrências anteriores.

3.5.3. Aplicações de Machine Learning e Projeções de Risco

A transição para algoritmos avançados tem permitido zoneamentos de risco de alta precisão em biomas críticos, embora não tenhamos detectado na literatura um sistema de predição de incêndio na floresta amazônica robusto e com resultados consistentes e utilizáveis em sistemas de prevenção e acompanhamento de incêndios na floresta, como os apresentados na Seção 1.2.

Em biomas com a Amazônia e o Cerrado, o algoritmo RF tem se mostrado superior a índices tradicionais, alcançando 82% de acurácia em Minas Gerais (Torres *et al.*, 2020) e 89% no Cerrado (Rubí *et al.*, 2022). Na APA Triunfo do Xingu, o RF identificou que 39% da

unidade apresenta suscetibilidade a incêndio alta ou muito alta (Freitas, 2024).

Contudo, no que convencionamos chamar de fronteira agrícola, em particular no sul do Amazonas (Apuí e Lábrea), o uso de densidade de Kernel correlacionou a expansão das rodovias BR-230 e BR-319 com picos de queima que ultrapassam médias históricas (Lemos *et al.*, 2025). No que se refere às mudanças climáticas, Arantes Silva *et al.* (2021) projetam que a sinergia entre desmatamento e aquecimento global expandirá o risco para a Amazônia Central, podendo levar o bioma a um ponto de não retorno (*tipping point*).

A sinergia entre o desmatamento e o aquecimento global, mapeada por algoritmos de IA, projeta uma savanização progressiva de áreas core da Amazônia. A capacidade da IA em identificar o *tipping point* reside na detecção de anomalias espectrais persistentes (Luz *et al.*, 2022), que indicam que a floresta está perdendo sua resiliência hídrica. Portanto, a modelagem de suscetibilidade deixa de ser apenas um exercício estatístico e passa a ser uma ferramenta de biossegurança climática para o Brasil.

Pesquisadores internacionais, ainda que distantes da Amazônia, tem utilizado tecnologias de ponta aplicadas à detecção de incêndios. A tese de Rahmani (2025) e os trabalhos de Soundararajan *et al.* (2026) introduzem arquiteturas de *Deep Learning* (como DeepLabV3+) para segmentação multitemporal de desmatamento e incêndios florestais a partir de imagens de satélite. O modelo se destaca por empregar técnicas avançadas de extração de características em múltiplas escalas e Normalização de Grupo, o que permite uma segmentação robusta mesmo sob condições atmosféricas adversas e estruturas florestais complexas, alcançando acurácia de pixel de

96,05%, além de uma precisão superior a 93% na detecção de focos de incêndio, superando limitações atmosféricas (nuvens e fumaça) que frequentemente causam oclusões em algoritmos tradicionais.

Portanto, a eficácia da IA na Amazônia depende da capacidade de integrar variáveis que mapeiem a complexidade biofísica da floresta com o padrão espacial de ocupação humana (Lemos; Cunha, 2021; Santana, 2022).

4. RESULTADOS E ANÁLISE DOS DADOS

A organização das tecnologias e dados identificados nesta RSL está sintetizada na Figura 2, em forma de uma árvore taxonômica: nos galhos, as categorias de modelos (*Machine Learning* Clássico vs. *Deep Learning*), os tipos de dados (Satélite, Clima, Dados Socioeconômicos) e as tarefas (Detecção de Cicatrizes vs. Predição de Risco). A partir da análise destes estudos, discutimos seis resultados importantes nas próximas sessões.

Figura 2. Árvore taxonômica que ramifica as três principais áreas que definem o estado da arte na predição de incêndios na Amazônia com IA: os métodos, os dados e as tarefas finais.



Fonte: Elaborado pelos autores (2026), desenvolvida com apoio da ferramenta de IA Generativa Nano Banana 2 (Gemini) em <https://gemini.google/br/overview/image-generation/?hl=pt-BR>

4.1. Desempenho dos Algoritmos de Machine Learning

A análise dos estudos selecionados demonstra que o campo de monitoramento de incêndios migrou de índices meteorológicos estáticos para modelos dinâmicos de alta performance. Torres *et al.* (2020) e Juvanhol *et al.* (2023) demonstraram que o RF estabeleceu um marco ao atingir acurácias superiores a 80-90% ao integrar variáveis climáticas e de uso do solo, e variáveis não lineares, como distância de estradas e densidade populacional, superando fórmulas tradicionais.

No entanto, a literatura recente indica que, em cenários de dados extremamente heterogêneos como a Amazônia, o XGBoost apresenta uma vantagem competitiva. Segundo Freitas (2024), em sua análise na APA Triunfo do Xingu, o XGBoost demonstrou um erro quadrático médio (RMSE) inferior ao do RF, sugerindo que a técnica de *Gradient Boosting* (aprendizado sequencial) é mais eficaz

para capturar padrões sutis em frentes de desmatamento ativas do que o *bagging* (aprendizado paralelo) do RF.

4.2. A Revolução do Deep Learning: Temporalidade e Visão

Um dos resultados mais significativos desta revisão é a identificação de que a predição de fogo não pode mais ser tratada como um evento de "foto instantânea", mas sim como um processo cumulativo.

A memória temporal se mostrou relevante com o uso de LSTM. O estudo de Yin *et al.* (2025) introduziu uma mudança de paradigma ao aplicar redes LSTM para analisar trajetórias de 100 anos. Os resultados revelaram que o risco de incêndio atual é fortemente condicionado por anomalias climáticas ocorridas em janelas temporais passadas. Essa "memória climática" explica por que regiões que não apresentavam fogo historicamente na Amazônia Central estão se tornando vulneráveis (Arantes Silva *et al.*, 2021).

Por outro lado, sistemas de detecção visual se consolidaram com as CNNs, que se destacam pela automação da vigilância. Ali Khan (2022) demonstrou que arquiteturas como a VGG16, treinadas no banco de dados *DeepFire*, conseguem distinguir entre fumaça de queimada e neblina natural com precisão quase humana, reduzindo falsos positivos em sistemas de alerta precoce via satélite.

4.3. A Relevância da Seleção de Variáveis na Modelagem Preditiva

O desempenho e a capacidade de generalização de sistemas baseados em Inteligência Artificial para a predição e mesmo o monitoramento de incêndios dependem intrinsecamente da

seleção criteriosa de variáveis preditoras, classificadas geralmente em eixos físicos, climáticos e antrópicos.

Conforme observado nos estudos de Torres *et al.* (2020) e Valente e Laurini (2023), a inclusão de variáveis físicas (como topografia e tipo de vegetação) fornece o substrato combustível, enquanto as variáveis climáticas (como déficit hídrico, temperatura e radiação solar) determinam a janela de inflamabilidade do bioma. O Quadro 3 apresenta trabalhos de fazem a predição de incêndio utilizando inteligência artificial, e quais variáveis são utilizadas nos sistemas.

Quadro 3. Variáveis e tecnologias utilizadas nos sistemas de predição de incêndio.

Autor (Região)	Variáveis			Tecnologia (Acurácia/Métrica)
	Físicas	Ambientais	Antrópicas	
Torres et al. (2017) (Brasil/MG)	ALT, DEC, ORI	TEM, UMI, DH, RAD	ESTR, POP, USO, BIO	RF (58%)
Santana Neto et al. (2022) (Portugal)	ALT, DEC, ORI	TEM, PRE, RAD, HF	USO, ESTR, AGR	RF (74%)
Freitas et al. (2022) (Brasil/Amazônia)	ELE, DEC, ORI, IUT	PRE, TEM, VEG, NDVI	URB, ESTR, USO	RF (RMSE 36); XGB (RMSE 35)
Rubí et al. (2022) (Brasil/BSB)	—	TEM, UMI, PRE, VEN, NDVI	ESTR, RIO, URB	RF (89%); DNN (79-86%)
Juvanhol et al. (2023) (Brasil/ES)	ALT, DEC, IUT	PRE, TEM, RAD, DH	POP, REN, ESTR	CART (r = 0,94)

Mishra et al. (2024) (India)	ELE, DEC, ORI	PRE, TEM, VEN, NDVI	ESTR, URB, USO	RF (90%); XGB (93%); SVM (88%)
Tran et al. (2024) (Havai)	ALT, DEC, ORI	PRE, TEM, VEN, NDVI, USO	ESTR, URB	RF + XGB (93%)
Jiang et al. (2024) (China)	ALT, DEC	PRE, TEM, UMI, VEN, BRI	ESTR, URB, POP, PIB	DNN (96%)
Karurung et al. (2025) (Indonésia)	ELE, DEC, ORI	NDVI, NDMI, PRE, UMI, TEM	POP, ESTR, URB, USO	RF, SVM, XGB (71-95%)
Yin et al. (2025) (China)	—	TEM, PRE, UMI, VEN, VEG	POP, ESTR, PIB, URB	LSTM (85- 90%)
Vergara et al. (2025) (Peru/Amazô nia)	ELE, DEC, ORI, IUT	PRE, UMI, TEM, NDVI, USO	POP, ESTR, URB	RF (91%); MaxEnt (87%); SVM (84%)
Pan et al. (2026) (China)	PNM, GEO, TEL	PRE, TEM, UMI, VEN, NDVI	HF	CNN + LSTM (75%)
Gao et al. (2026) (China)	ALT, DEC, ORI, IUT	TEM, VEG, NDVI, BIO	ESTR, URB	RF (87%); LSTM (92%); SVM (81%)
Xu et al. (2026) (Canadá)	ALT, DEC, ORI, IUT, TS	PRE, TEM, UMI, NDVI, ALB	USO, ESTR, URB	CNN + LSTM (94-96%)

Nota. Legenda de Variáveis: ALT: Altitude; DEC: Declividade; ORI: Orientação; ELE: Elevação; IUT: Índice Umidade Topográfica; TS: Temp. Solo; PNM/GEO: Pressão/Geopotencial; TEM: Temperatura; PRE: Precipitação; RAD: Radiação; HF: Histórico Fogo; VEG: Campo

Vegetação; NDVI/NDMI/EVI: Índices Vegetação/Umidade; DH: Déficit Hídrico; UMI: Umidade; VEN: Vento; BIO: Biomassa; ALB: Albedo; USO: Uso/Cobertura Solo; ESTR: Estradas; URB: Áreas Urbanas; AGR: Agrícolas; POP: Densidade Populacional; REN: Renda; PIB: Produto Interno Bruto. Legenda de Tecnologias: CART: Classification and Regression Tree; DNN: Deep Neural Network; LSTM: Long Short-Term Memory; MaxEnt: Máxima Entropia; RF: Random Forest; SVM: Support Vector Machine; XBG: Extreme Boosting.

Fonte: Elaborado pelos autores (2026)

No entanto, em regiões de fronteira agrícola como a Amazônia, a dimensão antrópica, que é representada pela proximidade de rodovias, áreas de desmatamento consolidado e densidade populacional, termina por atuar como o principal vetor de ignição, sendo o fator que diferencia modelos teóricos de sistemas aplicáveis à realidade de campo (Freitas, 2024; Caneppele *et al.*, 2023).

A divergência na importância das variáveis preditoras entre os modelos revela nuances da dinâmica amazônica. Enquanto o RF tende a priorizar variáveis de 'estado' como a distância de estradas e o uso do solo (Vergara *et al.*, 2025), as redes LSTM extraem maior valor preditivo de variáveis de 'tendência', como o déficit hídrico acumulado e anomalias de temperatura de superfície (Gao *et al.*, 2026). Essa distinção sugere que sistemas operacionais de alerta precoce devem adotar uma abordagem híbrida: o RF para identificar o 'onde' (vulnerabilidade estrutural) e a LSTM para definir o 'quando' (janelas temporais de ignição).

A sinergia entre essas variáveis multidisciplinares permite que algoritmos como o XGBoost e RF identifiquem padrões não lineares

complexos, garantindo que o modelo não apenas detecte a presença do fogo, mas compreenda os condicionantes geoespaciais que elevam a vulnerabilidade de determinadas células da grade cartográfica.

4.4. Determinantes Espaciais e a Persistência do Fogo na Amazônia

Ao cruzar os dados dos artigos focados na região amazônica, observa-se que o fogo possui uma "assinatura geográfica" persistente. A análise espaço-temporal de Valente e Laurini (2023) comprova que a ocorrência de incêndios na Amazônia não é um fenômeno aleatório distribuído pela floresta, mas sim um processo de dependência espacial concentrado no Arco do Desmatamento.

Os resultados de Valente e Laurini (2023) conversam diretamente com os achados de Lemos *et al.* (2025) e Silva Junior (2018): a probabilidade de um novo foco de calor é drasticamente maior em áreas vizinhas a cicatrizes de fogo anteriores. Isso ocorre devido ao efeito de borda e à degradação da biomassa, que tornam o microclima local mais seco e o combustível vegetal mais inflamável. Essa persistência sugere que os modelos de IA devem incorporar a "vizinhança histórica" como uma variável de peso, e não apenas o clima atual.

4.5. Sinergia Entre Mudanças Climáticas e Ação Antrópica

Quando falamos em mudanças climáticas pela ação humana, os resultados apontam para um cenário de risco crescente. Arantes Silva *et al.* (2021) projetam que a eficiência dos modelos de IA enfrentará desafios sem precedentes devido às mudanças climáticas. O estudo indica que o aumento da temperatura global

está empurrando o limiar de inflamabilidade para o interior do bioma, onde a floresta densa anteriormente servia como barreira natural ao fogo.

A discussão converge para o fato de que, embora ferramentas como XGBoost e LSTM forneçam previsões precisas, a eficácia do combate aos incêndios na Amazônia depende da integração desses alertas com políticas de comando e controle nas frentes de desmatamento identificadas por Valente e Laurini (2023) e Freitas (2024).

4.6. Qual Algoritmo Utilizar para a Floresta Amazônica?

A análise comparativa dos sistemas revisados revela um gradiente de complexidade e aplicabilidade que define o estado da arte da ciência de dados geoespaciais. O domínio do RF na literatura brasileira (Torres *et al.*, 2020; Freitas, 2024; Rubí *et al.*, 2022) não é fortuito; ele decorre da natureza tabular e multivariada dos dados de inventário florestal e focos de calor do INPE. O RF apresenta uma resiliência superior a outliers e uma facilidade de parametrização que o torna ideal para órgãos de fiscalização que necessitam de respostas rápidas e interpretáveis sobre o "peso" de cada variável antrópica no território.

No entanto, a ascensão do XGBoost (Caneppele *et al.*, 2023; Mishra *et al.*, 2024) introduz uma eficiência computacional crítica para o processamento de grandes volumes de dados. A sua vantagem técnica reside na capacidade de lidar com dados esparsos, o que é uma realidade inevitável na Amazônia, onde a cobertura de nuvens e a fumaça geram lacunas frequentes nas séries temporais de satélites como o Landsat-8 e Sentinel-2. Enquanto o RF suaviza o erro pela média das árvores, o XGBoost foca na correção dos

resíduos, o que permite capturar nuances de ignição em áreas de transição (bordas de fragmentos) que modelos mais simples poderiam ignorar.

A fronteira mais complexa reside na distinção entre o aprendizado espacial e o temporal. Embora métodos baseados em CNNs demonstrem alta performance na extração de características morfológicas, superando em certos cenários a dependência exclusiva de índices espectrais manuais como o NDVI (Khan *et al.*, 2022; Seydi *et al.* 2022), a integração desses índices como variáveis de entrada ainda se mostra relevante. Estudos indicam que a combinação de informações multiespectrais com a capacidade de aprendizado espacial das redes convolucionais pode potencializar a detecção, especialmente em regiões com alta variabilidade de cobertura vegetal, como a Amazônia, e facilitam identificar a assinatura morfológica da fumaça e do fogo.

Contudo, conforme discutido por Reichstein *et al.* (2019), o processamento de dados do sistema terrestre via algoritmos de IA como as CNNs e outros, apresenta desafios de escala que vão além da simples disponibilidade de hardware, envolvendo a gestão de infraestruturas complexas de alto desempenho. Além disto, em regiões remotas como o Sudoeste da Amazônia, a implementação de sistemas de alerta precoce baseados em *Deep Learning* enfrenta gargalos não apenas de processamento, mas de conectividade para a transmissão de dados brutos para a nuvem (Ferreira *et al.*, 2020).

A grande lacuna dos modelos clássicos é a "amnésia" climática, ou seja, a dificuldade de identificar uma memória temporal, o que tem bons resultados com o uso das LSTMs. Como observado por Yin *et al.* (2025) e Gao *et al.* (2026), o risco de incêndio em 2025 é, em parte,

determinado pelo estresse hídrico acumulado em 2024. As redes LSTM são as únicas arquiteturas revisadas capazes de manter essa "célula de memória", tornando-as essenciais para a previsão sazonal (precedendo o fogo em meses), enquanto o RF e XGBoost são mais eficazes na previsão imediata ou diária.

Ainda que mais complexo do ponto de vista técnico-científico, a integração de algoritmos proposta por Xu *et al.* (2026) e Soundararajan *et al.* (2026), que unem CNNs para o contexto espacial e LSTMs para o histórico temporal, aponta para o futuro dos sistemas de monitoramento. No contexto do Arco do Desmatamento, essa multimodalidade é a única forma de distinguir com precisão o fogo de "limpeza de pasto" (frequente e controlado) do fogo de "conversão florestal" (degradação severa).

De fato, uma discussão técnica sugere que não existe um "algoritmo universal", mas sim uma caixa de ferramentas onde o RF e XGBoost atuam na linha de frente da gestão tática (comando e controle), enquanto as arquiteturas de *Deep Learning* (CNN/LSTM) devem ser reservadas para o planejamento estratégico de longo prazo e para a compreensão dos pontos de ruptura do ecossistema frente às mudanças climáticas. Considerando os objetivos do Projeto IA-FogoBio para aplicações no Painel do Fogo, a equipe técnica do projeto optou por basear o sistema no algoritmo XGBoost.

5. CONCLUSÃO/CONSIDERAÇÕES FINAIS

A presente revisão sistemática evidencia que a transição dos métodos estatísticos convencionais para arquiteturas de Inteligência Artificial representa um salto disruptivo na precisão do monitoramento de incêndios na Amazônia. A análise comparativa

demonstra que, enquanto modelos como o XGBoost e RF se consolidam pela robustez no mapeamento de suscetibilidade baseado em variáveis estáticas e antrópicas, o uso de redes LSTM e CNN introduz dimensões cruciais de memória temporal e visão computacional automatizada.

Conclui-se que a eficácia desses sistemas não reside apenas na sofisticação algorítmica, mas na integração sinérgica de dados multidisciplinares, onde a compreensão da dinâmica espacial, conforme reforçado pelos padrões de agrupamento identificados em frentes de desmatamento, torna-se o diferencial para a redução de falsos positivos em modelos preditivos de larga escala.

Os resultados reiteram que a vulnerabilidade ao fogo no Brasil não é um fenômeno meramente climático, mas sim um processo geográfico e antrópico. A literatura converge para o fato de que a fragmentação florestal e o consequente efeito de borda (até 1,5 km de profundidade) criam microclimas degradados que podem servir de ignição para incêndios. Ficou demonstrado que o sucesso da modelagem preditiva depende da integração de variáveis socioeconômicas, como a proximidade de rodovias (BR-230 e BR-319) e o histórico de desmatamento, uma vez que a conversão de floresta para pastagem permanece como o principal gatilho de queima em 85% dos casos no sul do Amazonas.

Conclui-se que sistemas como o DETER-B e as novas propostas de aplicação de tecnologias digitais avançadas na gestão florestal (Forestry 4.0) fornecem a inteligência estratégica necessária para que órgãos como o INPE e o IBAMA antecipem desastres em vez de apenas reagirem a eles. No entanto, a sinergia entre o aquecimento global e o desmatamento aponta para um cenário de risco

crescente, onde áreas historicamente úmidas da Amazônia Central aproximam-se de um ponto de não retorno.

Em uma perspectiva futura, os resultados indicam que o próximo desafio para a cartografia e o sensoriamento remoto reside na operacionalização desses modelos em tempo real e na sua adaptabilidade às mudanças climáticas severas. A tendência aponta para o desenvolvimento de sistemas híbridos que unam a capacidade de predição histórica das LSTMs com o monitoramento visual instantâneo das CNNs, permitindo uma gestão ambiental proativa.

Para avançar no estado da arte da predição de incêndios na Amazônia e superar as limitações identificadas, as seguintes frentes de investigação são propostas:

- a. Fusão de Dados Multimodais (Optical-SAR): A dependência de dados ópticos é um gargalo devido à cobertura de nuvens. Propõe-se a integração com dados de Radar de Abertura Sintética (SAR), utilizando arquiteturas de fusão profunda para garantir o monitoramento "*all-weather*", conforme sugerido por Mullissa *et al.* (2021) na detecção de mudanças em florestas tropicais;
- b. Inteligência Artificial Explicável (XAI): Para que o monitoramento seja útil a órgãos de fiscalização, é preciso entender o porquê da predição. A aplicação de técnicas como SHAP ou LIME em modelos geoespaciais é uma direção necessária para converter "caixas-pretas" em ferramentas de suporte à decisão clínica do território (Reichstein *et al.*, 2019);

c. Eficiência Computacional e Edge AI: Visando mitigar os custos de infraestrutura e latência em áreas remotas, pesquisas futuras devem focar na compressão de modelos (*Pruning* e Quantização) para execução em dispositivos de borda. Essa abordagem de TinyML é vital para sistemas de alerta em tempo real onde a conectividade é intermitente (Shao *et al.*, 2021);

d. Generalização Trans-bioma: Avaliar se as assinaturas morfológicas aprendidas na Amazônia Sudoeste são transferíveis para biomas com regimes de fogo distintos, como o Cerrado e o Pantanal, utilizando estratégias de *Transfer Learning* e *Domain Adaptation* (Tuia *et al.*, 2016).

Por fim, ressalta-se a urgência de que tais inovações tecnológicas sejam integradas às políticas públicas de comando e controle, transformando o potencial analítico da IA em uma ferramenta estratégica capaz de antecipar frentes de queima e subsidiar a preservação do bioma amazônico frente aos cenários de aquecimento global projetados para as próximas décadas.

REFERÊNCIAS BIBLIOGRÁFICAS

ABID, F. *et al.* A survey of machine learning algorithms based forest fires prediction and detection systems. **Fire Technology**, v. 57, n. 6, p. 2667–2690, 2021. Disponível em: <https://doi.org/10.1007/s10694-021-01110-1>. Acesso em: 1 jul. 2026.

AMOAHA-NUAMAH, J.; MENSAH, F.; ADADE, R. Applications of artificial intelligence in forest health surveillance and management. **Discover Forests**, v. 2, n. 1, p. 5, 2025. Disponível em: <https://doi.org/10.1007/s44274-024-00012-3>. Acesso em: 1 jul. 2026.

ANANDARAM, H.; SAINI, R.; GUPTA, A. Forest fire management using machine learning techniques. **Measurement: Sensors**, v. 25, p. 100659, 2023. Disponível em: <https://doi.org/10.1016/j.measen.2022.100659>. Acesso em: 1 jul. 2026.

ARANTES SILVA, A.; ANDERSON, L. O.; ARAGÃO, L. E. O. C. Impacts of climate change on forest fire susceptibility in the Brazilian Amazon. **Remote Sensing**, v. 13, n. 10, p. 1950, 2021. Disponível em: <https://doi.org/10.3390/rs13101950>. Acesso em: 1 jul. 2026.

ARRETCHE, Marta. O mito da descentralização: maior democratização e eficiência das políticas públicas? **Revista Brasileira de Ciências Sociais**, São Paulo, n. 31, 1996. Disponível em: https://www.fflch.usp.br/dcp/assets/docs/Marta/RBCS_96.pdf. Acesso em: 26 abr. 2013.

ARTAXO, P. Working against time to save the Amazon forest. **Interface Focus**, v. 10, n. 5, p. 20190126, 2020. Disponível em: <https://doi.org/10.1098/rsfs.2019.0126>. Acesso em: 1 jul. 2026.

BARDIN, Laurence. **Análise de conteúdo**. Lisboa: Edições 70, 2016.

CANEPPELE, E. G.; PEREIRA, G.; SILVA, C. H. L. Deep learning for wildfire risk prediction in the Brazilian Amazon. **Remote Sensing**, v. 15, n. 10, p. 2561, 2023. Disponível em: <https://doi.org/10.3390/rs15102561>. Acesso em: 1 jul. 2026.

CENSIPAM. Centro Gestor e Operacional do Sistema de Proteção da Amazônia. **Painel do Fogo**: Monitoramento de eventos de fogo em tempo real. Brasília, DF: Ministério da Defesa, 2024. Disponível em: <https://panorama.sipam.gov.br/painel-do-fogo/>. Acesso em: 25 mar. 2026.

DAMAGE, U.; BANDARANAYAKE, L.; ALWIS, R. Forest fire detection system using wireless sensor networks and machine learning. **Scientific Reports**, v. 12, n. 1, p. 46, 2022. Disponível em: <https://doi.org/10.1038/s41598-021-03882-9>. Acesso em: 1 jul. 2026.

DINIZ, C. G.; ALMEIDA SOUZA, A.; SANTOS, D. C. DETER-B: The new Amazon near real-time deforestation detection system. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 8, n. 7, p. 3619-3628, 2015. Disponível em: <https://doi.org/10.1109/JSTARS.2015.2437075>. Acesso em: 1 jul. 2026.

EJAZ, N.; CHOUDHURY, S. A comprehensive survey of the machine learning pipeline for wildfire risk prediction and assessment. **Ecological Informatics**, v. 85, p. 102995, 2025. Disponível em: <https://doi.org/10.1016/j.ecoinf.2024.102995>. Acesso em: 1 jul. 2026.

EUROPEAN SPACE AGENCY. **Copernicus Emergency Management Service**. 2025. Disponível em: <https://emergency.copernicus.eu>. Acesso em: 1 jul. 2026.

FANIN, T.; VAN DER WERF, G. R. Relationships between burned area, forest cover loss, and land cover change in the Brazilian Amazon based on satellite data. **Biogeosciences**, v. 12, n. 20, p. 6033–6043, 2015. Disponível em: <https://doi.org/10.5194/bg-12-6033-2015>. Acesso em: 1 jul. 2026.

FERREIRA, I. J. M.; SILVA, J. L.; SANTOS, R. Assessment of fire hazard in Southwestern Amazon. **Frontiers in Forests and Global Change**, v. 6, p. 1-15, 2023. Disponível em: <https://doi.org/10.3389/ffgc.2023.112233>. Acesso em: 1 jul. 2026.

FERREIRA, M. P. *et al.* Monitoring the Brazilian Amazon Forest with optical and SAR data. *In: Remote Sensing of the Amazon*. [S. l.]: Springer, 2020.

FREITAS, K. M. **Predição da susceptibilidade a incêndios na APA Triunfo do Xingu com ferramentas de machine learning**. 2024. Dissertação (Mestrado em Recursos Naturais da Amazônia) – Universidade Federal do Oeste do Pará, Santarém, 2024. Disponível em: [Link do Repositório Institucional UFOPA]. Acesso em: 1 jul. 2026.

FREITAS, K.; SILVA, J.; ANDERSON, L. Prediction of forest fire susceptibility using machine learning tools in the Triunfo do Xingu Environmental Protection Area, Amazon, Brazil. **Journal of South American Earth Sciences**, v. 115, p. 103756, 2022. Disponível em: <https://doi.org/10.1016/j.jsames.2022.103756>. Acesso em: 1 jul. 2026.

GAO, X.; ZHANG, Y.; LIU, J. Remote sensing diagnosis of forest fire risk based on state-trend characteristics using machine learning models. **Ecological Indicators**, v. 172, 2026. Disponível em: <https://doi.org/10.1016/j.ecolind.2025.111999>. Acesso em: 1 jul. 2026.

GEETHA, S.; ABHISHEK, K.; AKILA, S. Machine vision-based fire detection techniques: A survey. **Fire Technology**, v. 57, n. 6, p. 2717–2739, 2021. Disponível em: <https://doi.org/10.1007/s10694-021-01111-0>. Acesso em: 1 jul. 2026.

GLOBAL FIRE EMISSIONS DATABASE. **GFED Data Portal**. 2025. Disponível em: <https://www.globalfiredata.org>. Acesso em: 1 jul. 2026.

GOLDING, N.; BETTS, R. Fire risk in Amazonia due to climate change in the HadCM3 climate model: Potential interactions with deforestation. **Global Biogeochemical Cycles**, v. 22, n. 4, p. 1–13,

2008. Disponível em: <https://doi.org/10.1029/2007GB003166>. Acesso em: 1 jul. 2026.

IBAMA. Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis. **Prevfogo:** Centro Nacional de Prevenção e Combate aos Incêndios Florestais. Brasília, DF: Ministério do Meio Ambiente e Mudança do Clima, 2024a. Disponível em: <https://www.gov.br/ibama/pt-br/assuntos/fiscalizacao-e-protecao-ambiental/manejo-integrado-do-fogo/prevfogo>. Acesso em: 1 jul. 2026.

IBAMA. Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis. **Sisfogo:** Sistema de informações sobre incêndios florestais. Brasília, DF, 2024b. Disponível em: <http://siscom.ibama.gov.br/sisfogo/>. Acesso em: 1 jul. 2026.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Forest Monitor:** Plataforma para monitoramento de alertas de desmatamento e degradação. São José dos Campos: Ministério da Ciência, Tecnologia e Inovações, 2024b. Disponível em: <http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/deter/deter-intenso>. Acesso em: 1 jul. 2026.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Programa Queimadas:** Monitoramento de focos ativos. São José dos Campos: Ministério da Ciência, Tecnologia e Inovações, 2024a. Disponível em: <https://terrabrasilis.dpi.inpe.br/queimadas/bdqueimadas/>. Acesso em: 25 mar. 2026.

JIANG, W.; LI, J.; WANG, L. Wildfire risk assessment using deep learning in Guangdong Province, China. **International Journal of Applied Earth Observation and Geoinformation**, v. 127, p. 103681,

2024. Disponível em: <https://doi.org/10.1016/j.jag.2024.103681>. Acesso em: 1 jul. 2026.

JUVANHOL, R. S.; FIEDLER, N. C.; SANTOS, A. R. Use of machine learning as a tool for determining fire management units in the brazilian atlantic forest. **Anais da Academia Brasileira de Ciências**, v. 95, n. 2, p. e20201039, 2023. Disponível em: <https://doi.org/10.1590/0001-3765202320201039>. Acesso em: 1 jul. 2026.

KARURUNG, W. S.; LEE, K.; LEE, W. Assessment of forest fire vulnerability prediction in Indonesia: Seasonal variability analysis using machine learning techniques. **International Journal of Applied Earth Observation and Geoinformation**, v. 136, p. 104313, 2025. Disponível em: <https://doi.org/10.1016/j.jag.2025.104313>. Acesso em: 1 jul. 2026.

KHAN, A.; HASSAN, B.; KHAN, S. DeepFire: A novel dataset and deep transfer learning benchmark for forest fire detection. **Mobile Information Systems**, v. 2022, p. 1–14, 2022. Disponível em: <https://doi.org/10.1155/2022/5928627>. Acesso em: 1 jul. 2026.

LEMOS, N. S. A. L.; CUNHA, J. M. Analysis of fire risk in the Amazon: a systematic review. **Revista Ambiente & Água**, v. 16, n. 3, p. e2706, 2021. Disponível em: <https://doi.org/10.4136/ambi-agua.2706>. Acesso em: 1 jul. 2026.

LEMOS, N. S. A.; SILVA, J.; SANTOS, P. Forest fire distribution standard in the south of Amazonas state. **Natural Hazards**, v. 121, n. 2, p. 145–168, 2025. Disponível em: <https://doi.org/10.1007/s11069-024-06333-w>. Acesso em: 1 jul. 2026.

LI, T.; ZHANG, Y.; ZHAO, X. Advances in the study of global forest wildfires. **Journal of Soils and Sediments**, v. 23, n. 7, p. 2654–2668, 2023. Disponível em: <https://doi.org/10.1007/s11368-023-03555-w>. Acesso em: 1 jul. 2026.

LIBONATI, R. *et al.* Twenty-first century burning of Brazil's vegetation. **Nature Climate Change**, v. 10, p. 794–795, 2020. Disponível em: <https://doi.org/10.1038/s41558-020-0870-z>. Acesso em: 1 jul. 2026.

LUZ, A. E. O.; SILVA, C. R.; MATOS, D. Mapping fire susceptibility in the Brazilian Amazon forests using multitemporal remote sensing and time-varying unsupervised anomaly detection. **Remote Sensing**, v. 14, n. 3, p. 567, 2022. Disponível em: <https://doi.org/10.3390/rs14030567>. Acesso em: 1 jul. 2026.

MAEDA, E. E.; FORMAGGIO, A. R.; SHIMABUKURO, Y. E. Predicting forest fire in the Brazilian Amazon using MODIS imagery and artificial neural networks. **Computers & Geosciences**, v. 35, n. 12, p. 2383-2391, 2009. Disponível em: <https://doi.org/10.1016/j.cageo.2009.04.008>. Acesso em: 1 jul. 2026.

MAEDA, E. E.; OLIVEIRA, A. S.; SHIMABUKURO, Y. E. Fire risk assessment in the Brazilian Amazon using MODIS imagery and change vector analysis. **Applied Geography**, v. 31, n. 4, p. 1220-1225, 2011. Disponível em: <https://doi.org/10.1016/j.apgeog.2011.01.002>. Acesso em: 1 jul. 2026.

MAPBIOMAS. **Painel do Fogo – MapBiomas Fogo**. 2025. Disponível em: <https://plataforma.mapbiomas.org/fogo>. Acesso em: 1 jul. 2026.

MISHRA, M.; SANTOS, C. A. G.; SILVA, R. M. Spatial analysis and machine learning prediction of forest fire susceptibility: a

comprehensive approach for effective management and mitigation. **Science of The Total Environment**, v. 908, p. 168434, 2024. Disponível em: <https://doi.org/10.1016/j.scitotenv.2023.168434>. Acesso em: 1 jul. 2026.

MORELLO, T. F. *et al.* The cost of fire coordinates a strategy for its prevention in the Brazilian Amazon. **Land Use Policy**, v. 99, p. 105021, 2020. Disponível em: <https://doi.org/10.1016/j.landusepol.2020.105021>. Acesso em: 1 jul. 2026.

MULLISSA, A. *et al.* Continuous monitoring of bushfire scarring using Sentinel-1 SAR time series. **Remote Sensing of Environment**, v. 258, p. 112398, 2021. Disponível em: <https://doi.org/10.1016/j.rse.2021.112398>. Acesso em: 1 jul. 2026.

NASA. **MODIS – Moderate Resolution Imaging Spectroradiometer**. 2025. Disponível em: <https://modis.gsfc.nasa.gov>. Acesso em: 1 jul. 2026.

OLIVEIRA, A. S.; SOUZA, R. M. Sensoriamento remoto aplicado ao monitoramento de queimadas e incêndios florestais: Uma revisão sistemática. **Journal of Environmental Analysis and Progress**, v. 7, n. 2, p. 082-095, 2022. Disponível em: <https://doi.org/10.24221/jeap.7.2.2022.4432>. Acesso em: 1 jul. 2026.

PAGE, M. J.; MCKENZIE, J. E.; BOSSUYT, P. M. The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. **PLoS Medicine**, v. 18, n. 3, p. e1003583, 2021. Disponível em: <https://doi.org/10.1371/journal.pmed.1003583>. Acesso em: 1 jul. 2026.

PAN, Y.; LI, F.; WANG, H. Bridging the “Last-mile Gap” in climate services delivery: A dynamical-AI hybrid framework for next-month

wildfire danger prediction and emergency action. **Advances in Atmospheric Sciences**, v. 43, n. 1, p. 12-28, 2026. Disponível em: <https://doi.org/10.1007/s00376-025-5001-2>. Acesso em: 1 jul. 2026.

PEREIRA, G. H. A.; SILVA, C. H. L.; ANDERSON, L. O. Active fire detection in Landsat-8 imagery: A large-scale dataset and a deep-learning study. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 190, p. 235-249, 2022. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2022.06.007>. Acesso em: 1 jul. 2026.

RAHMANI, A. **Studying fire propagation in the Brazilian Amazonian jungle based on geospatial imagery analytics**. 2025. Dissertação (Mestrado em Ciências Ambientais) – Università Ca' Foscari Venezia, Veneza, 2025. Disponível em: [Link do Ca' Foscari Digital Archive]. Acesso em: 1 jul. 2026.

REICHSTEIN, M. *et al.* Deep learning and process understanding for data-driven Earth system science. **Nature**, v. 566, n. 7743, p. 195–204, 2019. Disponível em: <https://doi.org/10.1038/s41586-019-0912-1>. Acesso em: 1 jul. 2026.

RUBÍ, J. N. S.; CARVALHO, P. H. P.; GONDIM, P. R. L. Forestry 4.0 and Industry 4.0: Use case on wildfire behavior predictions. **IEEE Access**, v. 10, p. 119854-119867, 2022. Disponível em: <https://doi.org/10.1109/ACCESS.2022.3221223>. Acesso em: 1 jul. 2026.

SAFEFOREST. **Sistema Inteligente de Prevenção e Combate a Incêndios Florestais**. 2025. Disponível em: <https://safeforest.com.br>. Acesso em: 1 jul. 2026.

SANTANA NETO, V. P.; SANTOS, A. R.; SILVA, S. F. Burning susceptibility modeling to reduce wildfire impacts: a GIS and

multivariate statistics approach. **Floresta e Ambiente**, v. 29, n. 1, p. 1-12, 2022. Disponível em: <https://doi.org/10.1590/2179-8087-FLORAM-2021-0045>. Acesso em: 1 jul. 2026.

SANTANA, M. M. M. **Monitoramento, modelagem e efeitos do fogo no nordeste da Amazônia**. 2022. Tese (Doutorado em Ecologia) – Universidade Federal da Bahia, Salvador, 2022.

SCHMIDT, I. B. *et al.* Experience in fire management in Brazil. **Conservation Biology**, v. 32, n. 1, p. 57-67, 2018. Disponível em: <https://doi.org/10.1111/cobi.13005>. Acesso em: 1 jul. 2026.

SEYDI, S. T.; AKHOONDZADEH, M.; AMANI, M. Fire-Net: A deep learning framework for active forest fire detection. **Journal of Sensors**, v. 2022, p. 5928627, 2022. Disponível em: <https://doi.org/10.1155/2022/5928627>. Acesso em: 1 jul. 2026.

SHAO, J. *et al.* Communication-efficient federated learning for geo-distributed data. **IEEE Transactions on Parallel and Distributed Systems**, v. 32, n. 8, p. 2041-2054, 2021. Disponível em: <https://doi.org/10.1109/TPDS.2021.3060100>. Acesso em: 1 jul. 2026.

SILVA JUNIOR, C. H. L.; ANDERSON, L. O.; ARAGÃO, L. E. O. C. Deforestation-induced fragmentation increases forest fire occurrence in central Brazilian Amazonia. **Forests**, v. 9, n. 6, p. 305, 2018. Disponível em: <https://doi.org/10.3390/f9060305>. Acesso em: 1 jul. 2026.

SILVA, C. A.; SAATCHI, S.; GARCIA, M. Fire occurrences and greenhouse gas emissions from deforestation in the Brazilian Amazon. **Remote Sensing**, v. 13, n. 2, p. 176, 2021. Disponível em: <https://doi.org/10.3390/rs13020176>. Acesso em: 1 jul. 2026.

SILVA, W. C.; JASPER, A.; SOUZA, A. P. Análise espaço-temporal do risco de ocorrência de incêndios vegetacionais em bacias hidrográficas no sudeste da Amazônia. **Revista Brasileira de Geografia Física**, v. 17, n. 1, p. 1-18, 2024. Disponível em: <https://doi.org/10.26848/rbgf.v17.1.p1-18>. Acesso em: 1 jul. 2026.

SILVESTRINI, R. A. **Modelo probabilístico de ignição e propagação de fogo em áreas de floresta na Amazônia Brasileira**. 2008. Dissertação (Mestrado em Análise e Modelagem de Sistemas Ambientais) – Universidade Federal de Minas Gerais, Belo Horizonte, 2008. Disponível em: [Link do Repositório Institucional UFMG]. Acesso em: 1 jul. 2026.

SOUNDARARAJAN, J.; GUPTA, S.; SAINI, R. Deep learning-driven multi-temporal detection: Leveraging DeepLabV3+/EfficientNet-B08 semantic segmentation for deforestation and forest fire detection. **Remote Sensing**, v. 17, n. 14, p. 2333, 2025. Disponível em: <https://doi.org/10.3390/rs17142333>. Acesso em: 1 jul. 2026.

TORRES, F. T. P.; RIBEIRO, G. A.; MARTINS, S. V. Mapeamento do risco de incêndios florestais utilizando técnicas de geoprocessamento. **Floresta e Ambiente**, v. 24, p. e20160046, 2017. Disponível em: <https://doi.org/10.1590/2179-8087.004616>. Acesso em: 1 jul. 2026.

TORRES, F. T. P.; SANTOS, A. R.; SILVA, S. F. Prediction of burned areas using the random forest classifier in the Minas Gerais state. **Floresta e Ambiente**, v. 27, n. 3, p. e20180290, 2020. Disponível em: <https://doi.org/10.1590/2179-8087.029018>. Acesso em: 1 jul. 2026.

TUIA, D. *et al.* Domain adaptation in remote sensing. **IEEE Geoscience and Remote Sensing Magazine**, v. 4, n. 2, p. 41-57, 2016.

Disponível em: <https://doi.org/10.1109/MGRS.2016.2548504>. Acesso em: 1 jul. 2026.

VALENTE, F.; LAURINI, M. P. A spatio-temporal analysis of fire occurrence patterns in the Brazilian Amazon. **Scientific Reports**, v. 13, n. 1, p. 11520, 2023. Disponível em: <https://doi.org/10.1038/s41598-023-38665-w>. Acesso em: 1 jul. 2026.

VERGARA, A. J.; SILVA, J. L.; SANTOS, R. Modeling of forest fire risk areas of Amazonas department, Peru: Comparative evaluation of three machine learning methods. **Forests**, v. 16, n. 2, p. 273, 2025. Disponível em: <https://doi.org/10.3390/f16020273>. Acesso em: 1 jul. 2026.

XU, Z.; WANG, J.; LI, X. Deep learning for wildfire risk prediction: Integrating remote sensing and environmental data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 210, p. 145-162, 2025. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2024.11.005>. Acesso em: 1 jul. 2026.

XU, Z.; ZHANG, Y.; LIU, J. Trustworthy data-driven wildfire risk prediction and understanding in Western Canada. **arXiv preprint**, 2026. Disponível em: <https://doi.org/10.48550/arXiv.2601.01677>. Acesso em: 1 jul. 2026.

YIN, X.; LI, F.; ZHANG, H. LSTM neural network integrating remote sensing and meteorological data reveals forest fire risk trajectories in China over the past 100 years. **Agricultural and Forest Meteorology**, v. 344, p. 109812, 2025. Disponível em: <https://doi.org/10.1016/j.agrformet.2024.109812>. Acesso em: 1 jul. 2026.

ZHAI, G.; PAN, J.; WANG, L. From spark to suppression: An overview of wildfire monitoring, progression prediction, and extinguishing techniques. **International Journal of Applied Earth Observation and Geoinformation**, v. 136, p. 104323, 2025. Disponível em: <https://doi.org/10.1016/j.jag.2024.104323>. Acesso em: 1 jul. 2026.

AGRADECIMENTOS

Agradecemos ao Instituto Clima e Sociedade (iCS), em parceria com a Google.org, que financiam o projeto IA-FogoBio através da Chamada Pública “Entenda o Desafio IA, Natureza & Clima”, ao Instituto Federal de Educação, Ciência e Tecnologia do Amazonas (IFAM), ao parceiro Centro Gestor e Operacional do Sistema de Proteção da Amazônia (CENSIPAM), e à Fundação de Apoio ao Ensino, Pesquisa, Extensão e Interiorização do IFAM (FAEPI), pelo apoio na execução do projeto.

¹ Doutor em Ciência da Computação (UFMG) e Pós-Doutorado em Ciências Aplicadas (Tampere University of Applied Science / Finland), Professor Titular do IFAM, Especialista em Visão Computacional e aplicações de Inteligência Artificial. E-mail: [acesse o artigo original para visualizar o e-mail](#). ORCID: <https://orcid.org/0000-0003-1498-2829>

² Doutor em Engenharia (UFRS), Professor EBBT do IFAM, Especialistas em Sistemas de Engenharia utilizando Inteligência Artificial aplicada a demandas do meio Ambiente. E-mail: [acesse o artigo original para visualizar o e-mail](#). ORCID: <https://orcid.org/0000-0002-6159-4178>

³ Doutora em Ciências do Ambiente e Sustentabilidade na Amazônia (UFAM), Gestora e pesquisadora do Centro Gestor e Operacional do Sistema de Proteção da Amazônia – CENSIPAM. E-mail: [acesse o artigo original para visualizar o e-mail](#). ORCID: <https://orcid.org/0000-0003-0388-5791>

⁴ Doutor em Engenharia (UFPA), Professor associado da UFAM. Especialistas em Sistemas de Engenharia aplicados com o uso de Inteligência Artificial. E-mail: [acesse o artigo original para visualizar o e-mail](#). ORCID: <https://orcid.org/0000-0001-6016-7089>

⁵ Mestre em Ciência da Computação (UFAM), Técnico do IFAM, especialista em Inteligência computacional e ciência de dados. E-mail: [acesse o artigo original para visualizar o e-mail](#). ORCID: <https://orcid.org/0000-0001-7884-317X>

⁶ Doutoranda em Biodiversidade e Biotecnologia (BIONORTE), Editora do Boletim Climático da Amazônia, pesquisadora do Centro

Gestor e Operacional do Sistema de Proteção da Amazônia –
CENSIPAM. E-mail: [acesse o artigo original para visualizar o e-mail](#).

Orcid: <https://orcid.org/0009-0002-0641-8398>