



Instituto Federal de Minas Gerais
Campus Ouro Preto
Especialização em Inteligência Artificial



Arthur Cardoso Figueiredo

INTELIGÊNCIA ARTIFICIAL APLICADA À PREVENÇÃO E MITIGAÇÃO DE
DESASTRES NATURAIS: ABORDAGENS TÉCNICAS E PERSPECTIVAS FUTURAS

OURO PRETO
2025

ARTHUR CARDOSO FIGUEIREDO

INTELIGÊNCIA ARTIFICIAL APLICADA À PREVENÇÃO E MITIGAÇÃO DE
DESASTRES NATURAIS: ABORDAGENS TÉCNICAS E PERSPECTIVAS FUTURAS

Trabalho apresentado ao Colegiado do Curso de Pós-Graduação do Instituto Federal de Minas Gerais como parte dos requisitos para a conclusão do Curso de Pós-graduação em Inteligência Artificial.

Orientador: Profa. Dra. Sílvia Grasiella Moreira Almeida

OURO PRETO
2025



MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE MINAS GERAIS
Campus Ouro Preto
Diretoria de Pesquisa, Inovação e Pós-Graduação
Coordenação do Curso de Pós-graduação em Inteligência Artificial
Rua Pandiá Calógeras, 898 - Bairro Bauxita - CEP 35400-000 - Ouro Preto - MG
- www.ifmg.edu.br

FOLHA DE APROVAÇÃO

ARTHUR CARDOSO FIGUEIREDO

INTELIGÊNCIA ARTIFICIAL APLICADA À PREVENÇÃO E MITIGAÇÃO DE DESASTRES NATURAIS: ABORDAGENS TÉCNICAS E PERSPECTIVAS FUTURAS"

Trabalho de Conclusão de Curso
apresentado ao curso de
ESPECIALIZAÇÃO EM
INTELIGÊNCIA ARTIFICIAL,
ofertado pelo Instituto Federal de
Educação, Ciência e Tecnologia
de Minas Gerais - *Campus* Ouro
Preto, como parte dos requisitos
para a obtenção do título de
ESPECIALISTA EM
INTELIGÊNCIA ARTIFICIAL.

Aprovado em 11 de setembro de 2025, pela Banca Examinadora:

Profa. Dra. Sílvia Grasiella Moreira Almeida - IFMG Campus Ouro Preto - Orientadora

Profa. Ma. Cristina Alves Maertens - IFMG Campus Ouro Preto - Membro

Profa. Dra. Cristiana Santos Andreoli - IFMG Campus Ouro Preto - Membro

Ouro Preto, 11 de setembro de 2025.



Documento assinado eletronicamente por **Silvia Grasiella Moreira Almeida, Professora**, em 15/09/2025, às 08:52, conforme Decreto nº 10.543, de 13 de novembro de 2020.



Documento assinado eletronicamente por **Cristina Alves Maertens, Professora**, em 15/09/2025, às 09:00, conforme Decreto nº 10.543, de 13 de novembro de 2020.



Documento assinado eletronicamente por **Cristiana Santos Andreoli, Professora**, em 15/09/2025, às 09:44, conforme Decreto nº 10.543, de 13 de novembro de 2020.



A autenticidade do documento pode ser conferida no site <https://sei.ifmg.edu.br/consultadocs> informando o código verificador **2449421** e o código CRC **516EEA8E**.

F475i

Figueiredo, Arthur Cardoso.

Inteligência artificial aplicada à prevenção e mitigação de desastres naturais [manuscrito] : abordagens técnicas e perspectivas futuras / Arthur Cardoso Figueiredo. – 2025.
78 f. : il.

Orientadora: Sílvia Grasiella Moreira Almeida.

Trabalho de Conclusão de Curso (especialização) – Instituto Federal de Minas Gerais. *Campus* Ouro Preto, 2025.

1. Inteligência artificial. 2. Desastres naturais. 3. Aprendizado do computador. I. Almeida, Sílvia Grasiella Moreira. II. Instituto Federal de Minas Gerais. *Campus* Ouro Preto. III. Título.

CDU: 004.8

Catálogo: Kelly Cristiane Santos Moraes - CRB-6/3217

“O homem não teria alcançado o possível se, repetidas vezes, não tivesse tentado o impossível.”

- Max Weber

AGRADECIMENTOS

Agradeço, primeiramente, a Deus, por me conceder forças, saúde e sabedoria ao longo desta jornada.

Aos meus pais, Gustavo e Lourdinha, que me deram a dádiva de conviver com eles, aprendendo, por meio de seus exemplos, o valor do trabalho, da honestidade e dos grandes ensinamentos morais e éticos que levo para a vida.

À minha companheira, Cíntia, por estar ao meu lado em todos os momentos, com amor, paciência, incentivo e parceria. Sua presença foi essencial para que eu pudesse seguir em frente, mesmo nos dias mais difíceis.

Aos meus tios e tias, em especial à minha tia-madrinha Fatinha, e às tias Tina e Luzia, que contribuíram de forma significativa para minha formação acadêmica e pessoal. Aos meus avós, Conceição e Jaime, pelo legado de integridade, caráter inabalável e imenso amor, que levarei comigo para sempre.

Aos meus amigos Diego, Felipe e Leonardo, pela amizade sincera, apoio constante e presença nos momentos importantes dessa jornada.

À minha cunhada Pâmela, pelos conselhos, palavras de motivação e carinho ao longo desse caminho.

À Rádio Metralhas, pelas resenhas, os bons momentos e a leveza que tornaram essa caminhada mais divertida.

À professora Silvia Grasiella, coordenadora do programa de Pós-graduação e orientadora deste trabalho, pela dedicação, disponibilidade e orientação segura durante todo o processo. Sua contribuição foi fundamental para a concretização deste projeto.

A todos vocês, minha eterna gratidão.

RESUMO

Nas últimas décadas, a intensificação dos desastres naturais tem provocado impactos significativos em termos humanos, ambientais e econômicos. Nesse contexto, a Inteligência Artificial (IA) emerge como uma aliada estratégica para previsão, monitoramento e resposta a eventos extremos. Este trabalho analisa, de forma crítica e aplicada, metodologias recentes que utilizam IA na gestão de desastres, com ênfase em redes neurais profundas, algoritmos de classificação, modelagem preditiva e análise geoespacial. A investigação integra dados climáticos, geográficos e socioeconômicos, destacando estudos de referência como ATR HarmoniSAR, FloodNet e GeoDisasterAINet, além de contribuições da IA generativa. Os resultados evidenciam que a aplicação adequada dessas técnicas pode ampliar a precisão de previsões, otimizar o uso de recursos e fortalecer a resiliência de comunidades vulneráveis. Entretanto, desafios como qualidade e escassez de dados, custos de implementação, limitações técnicas e questões éticas ainda representam barreiras relevantes. Conclui-se que o avanço da IA aplicada à gestão de crises requer investimentos contínuos, políticas públicas consistentes e cooperação entre academia, governo e sociedade, a fim de transformar o potencial tecnológico em soluções práticas, transparentes e socialmente responsáveis.

Palavras-chave: Inteligência Artificial; Desastres Naturais; Aprendizado de Máquina; Modelagem Preditiva; Análise Geoespacial; Interpretação de Modelos

ABSTRACT

In recent decades, the intensification of natural disasters has generated profound human, environmental, and economic impacts. In this context, Artificial Intelligence (AI) has emerged as a strategic ally for forecasting, monitoring, and responding to extreme events. This work critically and practically examines recent methodologies that apply AI to disaster management, with emphasis on deep neural networks, classification algorithms, predictive modeling, and geospatial analysis. The study integrates climatic, geographic, and socioeconomic data, highlighting reference initiatives such as ATR HarmoniSAR, FloodNet, and GeoDisasterAINet, in addition to contributions from generative AI. The results indicate that, when properly applied, these techniques can enhance prediction accuracy, optimize resource allocation, and strengthen the resilience of vulnerable communities. However, challenges such as data scarcity and quality, implementation costs, technical limitations, and ethical concerns still represent relevant barriers. It is concluded that the advancement of AI in disaster management depends on continuous investment, consistent public policies, and collaboration between academia, government, and society, in order to transform technological potential into practical, transparent, and socially responsible solutions.

Keywords: Artificial Intelligence; Natural Disasters; Machine Learning; Predictive Modeling; Geospatial Analysis; Model Interpretability.

LISTA DE FIGURAS

Figura 1 - Categorias de desastres naturais e seus principais eventos. Classificação dos desastres naturais em categorias geofísicos, hidrológicos, meteorológicos, climatológicos, biológicos e extraterrestres, com respectivos eventos e perigos associados.	20
Figura 2 - Fluxograma de síntese dos estudos analisados. Representação esquemática dos quatro estudos selecionados (ATR HarmoniSAR, FloodNet, GeoDisasterAINet e Teoh et al., 2024) e suas principais técnicas associadas.	29
Figura 3 - Fluxo de processamento do sistema ATR HarmoniSAR.	32
Figura 4 - Interface do sistema ATR HarmoniSAR e exemplo de geração/harmonização de imagens sintéticas.	33
Figura 5 - Arquitetura do módulo ImageMixer (baseado em FineGAN).	33
Figura 6 - Exemplo de geração de máscaras: (a) seleção dos contornos; (b) máscara.	34
Figura 7 - Exemplos de cenários de desastre usados como background.	35
Figura 8 - Esquema da interpolação guiada pela equação de Poisson na harmonização.	36
Figura 9 - Matrizes de confusão e curvas precisão–revocação dos detectores treinados no ATR 1k Victim Dataset.	37
Figura 10 - Comparação: recorte direto (cut-and-paste) vs. harmonização por Poisson.	37
Figura 11 - Fluxo multiestágio do GeoDisasterAINet.	48
Figura 12 - Arquitetura do ensemble ERI-2025.	49
Figura 13 - Fluxograma Arquitetura GeoDisasterAINet.	49
Figura 14 - Desempenho do GeoDisasterAINet no Estágio 3 (CNNs + XGBoost + SVM Multiclasse)	51
Figura 15 - Matriz de confusão do modelo GeoDisasterAINet.	52
Figura 16 - Curvas ROC das quatro classes de desastres.	52
Figura 17 - Visualização LIME e Arquitetura do Ensemble GeoDisasterAINet.	54
Figura 18 - Estrutura do framework FloodIntel, combinando imagens reais e sintéticas para suporte à resposta em desastres.	57
Figura 19 - Exemplos de imagens sintéticas anotadas com bounding boxes em telhados.	58
Figura 20 - Distribuição da contagem de objetos por imagem no conjunto sintético.	58
Figura 21 - Número de parâmetros (M) e FLOPs (B) das variantes do YOLOv8.	59

Figura 22 - Comparação entre o ground truth e as predições das variantes YOLOv8 (n, s e m) em três cenários distintos de inundação, evidenciando o desempenho em área urbana com telhados de maior densidade e sobreposição.61

Figura 23 - Resultados de detecção do YOLOv8 (n, s e m) comparados ao ground truth em três cenários adicionais, destacando a variação do desempenho em ambientes com diferentes padrões arquitetônicos.62

LISTA DE TABELAS

Tabela 1 - Comparação de desempenho dos detectores treinados no COCO e com imagens.....	38
Tabela 2 - Comparação entre diferentes datasets utilizados em visão computacional	40
Tabela 3 - Quantidade de imagens e instâncias por classe no FloodNet.	41
Tabela 4 - Tipos de perguntas e respostas possíveis no VQA do FloodNet.....	42
Tabela 5 - Acurácia de classificação no FloodNet.	43
Tabela 6 - Resultados de segmentação semântica no FloodNet (IoU por classe e mIoU).	44
Tabela 7 - Resultados do VQA no FloodNet	45
Tabela 8 - Distribuição do dataset utilizado no GeoDisasterAINet.....	47
Tabela 9 - Resultados do estudo de ablação do GeoDisasterAINet.....	50
Tabela 10 - Métricas de desempenho por classe no GeoDisasterAINet (Estágio 3).	51
Tabela 11 - Resultados de desempenho do YOLOv8 com imagens sintéticas.	60
Tabela 12 - Resumo comparativo das metodologias de IA para gestão de desastres.	73

LISTA DE ABREVIATURAS E SIGLAS

ABNT - Associação Brasileira de Normas Técnicas

AP50 - Average Precision at $\text{IoU} \geq 0,5$

ATR HarmoniSAR - Automatic Target Recognition Harmonized Synthetic Aperture Radar

CNN - Convolutional Neural Network

CNNs - Redes Neurais Convolucionais

COBRaDE - Classificação e Codificação Brasileira de Desastres

COCO - Common Objects in Context Dataset

DL - Deep Learning

FloodNet - Dataset para análise de enchentes

FPS - Frames per Second

GANs - Generative Adversarial Networks

GeoDisasterAINet - Framework híbrido de classificação de desastres

IA - Inteligência Artificial

IoT - Internet of Things

IoU - Intersection over Union

IPEA - Instituto de Pesquisa Econômica Aplicada

LLM - Large Language Model

LLMs - Large Language Models

LIME - Local Interpretable Model-Agnostic Explanations

ML - Machine Learning

MFB - Multimodal Factorized Bilinear

ODS - Objetivos de Desenvolvimento Sustentável

ONU - Organização das Nações Unidas

PINN - Physics-Informed Neural Network

R-CNN - Region-based Convolutional Neural Network

SAN - Stacked Attention Network

SHAP - SHapley Additive exPlanations

SVM - Support Vector Machine

UFRN - Universidade Federal do Rio Grande do Norte

UNDRR - United Nations Office for Disaster Risk Reduction

VQA- Avaliação do Visual Question Answering

YOLO - You Only Look Once

YOLOv5x - You Only Look Once, versão 5x

SUMÁRIO

1	INTRODUÇÃO	14
2	CONTEXTUALIZAÇÃO E JUSTIFICATIVA	16
2.1	Objetivo	16
2.2	Objetivos Específicos	16
2.3	Justificativas e Relevância	17
3	FUNDAMENTAÇÃO TEÓRICA	18
3.1	Conceitos Fundamentais de Inteligência Artificial e Gestão de Desastres	18
3.1.1	Inteligência Artificial: Definições e Subcampos Relevantes	18
3.1.2	Desastres Naturais: Classificação e Ciclo de Gestão	19
3.1.3	Agenda 2030 e o ODS 11	21
3.2	Aplicações da Inteligência Artificial na Gestão de Desastres Naturais	22
3.3	Modelos Preditivos	23
3.4	Modelos Classificatórios	24
3.5	Análise Geoespacial e Sensoriamento Remoto	25
3.6	Discussão da Literatura	26
4	METODOLOGIA	28
4.1	Tipo de Pesquisa	28
4.2	Seleção dos Estudos	28
4.3	Procedimentos de Análise	30
4.4	CrITÉrios de Comparação	30
4.5	Aprofundamento nas Técnicas Seleccionadas	31
4.5.1	Aprofundamento Crítico em ATR HarmoniSAR (Mahmud <i>et al.</i> , 2024)	31
4.5.1.1	Seleção e síntese de foreground (vítimas)	32
4.5.1.2	Geração de máscaras e recorte poligonal	33
4.5.1.3	Seleção de backgrounds (cenários de desastre)	34
4.5.1.4	Composição e harmonização (Poisson Image Editing)	35
4.5.1.5	Geração automática de rótulos	36
4.5.1.6	Treinamento supervisionado (fine-tuning)	36

4.5.1.7 Avaliação e métricas	36
4.5.1.8 Síntese quantitativa	38
4.5.1.9 Limitações e desafios	38
4.5.1.10 Recursos computacionais	38
4.5.2 Aprofundamento Crítico em FloodNet (Rahnemoonfar <i>et al.</i> , 2021)	39
4.5.2.1 Aquisição dos dados e rotulagem	41
4.5.2.1.1 Construção do dataset	42
4.5.2.2 Análise Profunda de Segmentação Semântica	42
4.5.2.2.1 Divisão em treino/validação/teste	43
4.5.2.3 Avaliação do Visual Question Answering (VQA)	44
4.5.2.4 Perspectivas e Recomendações para a Comunidade de Pesquisa	45
4.5.2.5 Ambiente Computacional	45
4.5.2.6 Aprofundamento Crítico em GeoDisasterAINet (Raju <i>et al.</i> , 2025)	46
4.5.3 Arquitetura do Modelo Híbrido GeoDisasterAINet	48
4.5.4 Avaliação de Desempenho: Uma Análise Quantitativa e Comparativa	49
4.5.4.1 Métricas e Metodologia de Avaliação	49
4.5.4.2 O Modelo de Excelência: Análise Detalhada	50
4.5.5 A Confiança da Transparência: Interpretabilidade com LIME	52
4.5.6 Ambiente Computacional	55
4.5.7 Considerações e Próximos Passos	55
4.6 Revisão Crítica do Artigo “Exploring Generative AI for YOLOBased Object Detection to Enhance Flood Disaster Response in Malaysia”	56
4.6.1 YOLOv8 e IA Generativa na Detecção de Inundações: Introdução e Contextualização	56
4.6.2 O Framework FloodIntel	56
4.6.3 Construção e Preparação do Dataset Sintético	57
4.6.4 Treinamento e Arquitetura do YOLOv8	59
4.6.5 Resultados e Avaliação Crítica	59
4.6.6 Síntese Crítica	62
4.7 Análise Crítica e Síntese de Conhecimento do Artigo “Gestão de Crise Mediante a Utilização de IA” de Juan Manuel Corchado	63
4.7.1 Introdução e Contextualização do Estudo	63
4.7.2 Fundamentos e Evolução da IA: Perspectiva Histórica e Lições Aprendidas	64
4.7.3 IA Generativa e Grandes Modelos de Linguagem (LLMs): Definições e Capacidades Estratégicas	64

4.7.4 O Potencial da IA Generativa na Gestão de Crises: Uma Análise Multissetorial	65
4.7.5 Análise Crítica e Síntese Metodológica	66
4.7.6 Proposta de Aplicação Local: Previsão de Incêndios no Pico do Itacolomi (Ouro Preto/MG)	69
5 RESULTADOS	71
5.1 Análise Crítica e Síntese de Desempenho dos Modelos	71
5.1.1 GeoDisasterAINet (Raju <i>et al.</i> , 2025): Interpretabilidade e Robustez	71
5.1.2 FloodNet (Rahnemoonfar <i>et al.</i> , 2021): O Paradigma do Dataset de Alta Resolução	71
5.1.3 ATR HarmoniSAR e IA Generativa (Mahmud <i>et al.</i> , 2024; Teoh <i>et al.</i> , 2024): A Revolução dos Dados Sintéticos	72
6 CONSIDERAÇÕES FINAIS	74
REFERÊNCIAS	77

1 INTRODUÇÃO

Nas últimas décadas, a ocorrência e a intensidade dos desastres naturais vêm aumentando de forma significativa, impulsionadas por fatores como as mudanças climáticas, a expansão urbana desordenada, a degradação ambiental e o uso insustentável dos recursos naturais (Intergovernmental Panel on Climate Change, IPCC, 2022). Fenômenos como inundações, deslizamentos de terra, secas prolongadas, tempestades e incêndios florestais acarretam não apenas perdas humanas irreparáveis, mas também prejuízos expressivos à infraestrutura, à economia e aos ecossistemas (Organização das Nações Unidas, ONU, 2023). Esses impactos afetam diretamente a qualidade de vida das populações atingidas e tornam cada vez mais complexa a resposta a tais situações, reforçando a necessidade de estratégias eficazes de prevenção, mitigação e recuperação (Ahmad *et al.*, 2023).

Nesse cenário, cresce o interesse por soluções inovadoras que permitam antecipar riscos e apoiar decisões de formas mais assertivas. A Inteligência Artificial (IA), especialmente quando associada a técnicas avançadas de análise de dados e visão computacional, tem se consolidado como ferramenta estratégica na gestão de riscos e na resposta a desastres (Singh *et al.*, 2023). Os modelos de aprendizado profundo, em especial as redes neurais convolucionais (CNNs), quando combinados a sistemas de detecção de objetos e algoritmos de segmentação, demonstram elevado potencial para o processamento de grandes volumes de dados em tempo real. Essa integração possibilita desde o monitoramento contínuo de áreas suscetíveis a desastres até a identificação precisa de vítimas e a avaliação de danos estruturais (Luo *et al.*, 2022).

O amadurecimento dessas tecnologias favorece sua integração a sistemas de apoio à decisão utilizados diretamente em campo, aumentando a precisão das previsões e a agilidade das ações de resposta (Yin *et al.*, 2021). A combinação de dados provenientes de sensores remotos, drones e imagens de satélite com algoritmos de IA proporciona uma visão abrangente e dinâmica das ocorrências, contribuindo para intervenções mais rápidas e direcionadas (Zhang *et al.*, 2020).

Todavia, a aplicação da IA nesse contexto enfrenta desafios importantes, como a disponibilidade e a qualidade dos dados, barreiras tecnológicas, custos de implementação e questões éticas relacionadas à privacidade e ao uso responsável das informações (Liu *et al.*, 2022). Compreender tanto as potencialidades quanto as limitações dessas ferramentas é fundamental para garantir sua utilização de forma segura e eficiente. Mais do que um avanço tecnológico, trata-se de um desafio multidisciplinar que exige a integração de conhecimentos

técnicos, científicos, sociais e éticos, assegurando que as soluções desenvolvidas atendam às necessidades reais das comunidades e fortaleçam a resiliência urbana e comunitária (Kondo *et al.*, 2021).

Diante desse contexto, este trabalho tem como objetivo analisar, de forma crítica e aplicada, o uso de técnicas de IA na gestão de eventos extremos, avaliando sua aplicabilidade prática, suas limitações e seu potencial de aprimoramento, considerando diferentes fontes de dados e cenários de aplicação.

2 CONTEXTUALIZAÇÃO E JUSTIFICATIVA

2.1 Objetivo

Analisar criticamente e de forma aplicada o uso de técnicas de Inteligência Artificial (IA) na gestão de eventos extremos, avaliando sua aplicabilidade prática, limitações e potencial de aprimoramento, considerando diferentes fontes de dados e cenários de aplicação.

2.2 Objetivos Específicos

- Avaliar a aplicabilidade de metodologias de Inteligência Artificial na gestão de desastres naturais, contemplando dimensões técnicas, práticas, contextuais e interpretativas.
- Examinar os avanços e limitações de quatro estudos técnicos de referência — ATR HarmoniSAR, FloodNet, GeoDisasterAINet e a pesquisa de Teoh *et al.* (2024) — que exploram diferentes abordagens da IA em cenários de crise.
- Contextualizar o uso da IA a partir de uma perspectiva histórica, abordando os períodos de retrocesso conhecidos como “invernos da IA” e ressaltando a emergência da IA generativa como tecnologia de ruptura.
- Discutir a relevância de princípios éticos e de governança, como transparência, responsabilidade e prestação de contas, a fim de assegurar aplicações legítimas e socialmente confiáveis da IA em situações de risco.
- Estruturar uma metodologia que una inovação tecnológica, aplicabilidade prática e responsabilidade ética, voltada às demandas de gestão de riscos em Ouro Preto, reconhecida por sua alta suscetibilidade a desastres naturais. Ao mesmo tempo, a proposta mantém caráter adaptável a outros contextos brasileiros de vulnerabilidade socioambiental, garantindo relevância prática e potencial de replicação em diferentes cenários.

2.3 Justificativas e Relevância

A compreensão dos impactos dos desastres naturais já é amplamente documentada pela literatura científica e por organismos internacionais, como o IPCC (2022) e a ONU (2023). O desafio atual, entretanto, consiste em converter os avanços recentes em Inteligência Artificial (IA) em soluções efetivas para contextos de risco reais.

Embora haja progressos em metodologias que exploram aprendizado profundo, dados sintéticos e análise geoespacial (Mahmud; Kim, 2024; Rahnemoonfar *et al.*, 2021; Raju *et al.*, 2025), sua aplicação no Brasil ainda enfrenta entraves significativos. Entre eles destacam-se a escassez de bases de dados abertas, a infraestrutura tecnológica desigual e a limitada integração entre pesquisa acadêmica e políticas públicas. Esses fatores contribuem para que o país avance de forma mais lenta na incorporação prática dessas ferramentas, mesmo diante de sua elevada vulnerabilidade socioambiental.

Esse descompasso entre potencial tecnológico e aplicação prática reforça a necessidade de estudos que avaliem criticamente tais abordagens, destacando não apenas suas contribuições, mas também suas limitações em termos de infraestrutura, disponibilidade de dados e interpretabilidade dos modelos (Liu *et al.*, 2022; Kondo *et al.*, 2021).

Em países desenvolvidos, essas restrições tendem a ser menos pronunciadas, uma vez que contam com bases de dados consolidadas, maior investimento em inovação e políticas públicas consistentes voltadas à gestão de riscos. No Brasil, entretanto, tais dificuldades tornam-se mais evidentes, retardando a adoção prática de técnicas avançadas de IA.

Assim, ao analisar exemplos de referência internacional, este trabalho busca discutir como essas ferramentas podem ser adaptadas à realidade brasileira, em que vulnerabilidades sociais e ambientais coexistem com restrições estruturais (Instituto de Pesquisa Econômica Aplicada – IPEA, 2024).

3 FUNDAMENTAÇÃO TEÓRICA

3.1 Conceitos Fundamentais de Inteligência Artificial e Gestão de Desastres

3.1.1 Inteligência Artificial: Definições e Subcampos Relevantes

A Inteligência Artificial (IA) é entendida como a área responsável por projetar sistemas capazes de perceber o ambiente, interpretar informações e agir de maneira racional, orientados para a maximização de objetivos definidos (Russell; Norvig, 2013). Nesse campo, o *Machine Learning* (ML) ocupa papel central, pois possibilita que algoritmos aprendam a partir de dados, identificando padrões e realizando previsões sem depender de regras previamente programadas. De acordo com (Bishop, 2006), essa capacidade de generalização é sustentada por métodos estatísticos e probabilísticos, que fornecem aos modelos a robustez necessária para lidar com situações incertas e dados heterogêneos.

Tanto o ML quanto o *Deep Learning* (DL) têm como essência a identificação de padrões. A diferença é que, enquanto o ML aplica técnicas mais amplas de reconhecimento e classificação, o DL se destaca pela capacidade de extrair padrões mais complexos, especialmente em dados visuais ou em grandes volumes de informação. O DL, nesse sentido, pode ser compreendido como uma evolução dentro do ML, apoiada no uso de redes neurais artificiais compostas por múltiplas camadas, que permitem a extração de representações hierárquicas e cada vez mais sofisticadas dos dados. Essa característica torna o DL particularmente eficaz em tarefas de alta complexidade, como reconhecimento de imagens, processamento de linguagem natural e monitoramento de variáveis ambientais em tempo real (Russell; Norvig, 2013; Bishop, 2006).

Entre as arquiteturas mais aplicadas em geoprocessamento, as Redes Neurais Convolucionais (*Convolutional Neural Networks* – CNNs) vêm se destacando como ferramentas eficazes na análise de dados visuais e geoespaciais. Essas redes têm sido amplamente empregadas em tarefas como a detecção de padrões em imagens de satélite, o mapeamento de uso e cobertura da terra e o monitoramento de fenômenos ambientais em diferentes escalas (Meneses; Almeida, 2012). O algoritmo *You Only Look Once* (YOLO) também se mostra amplamente aplicado devido à sua capacidade de detecção de objetos em tempo real, permitindo identificar elementos críticos em cenários de crise, como vítimas, obstruções e danos estruturais (Teoh *et al.*, 2024, 2025).

Avanços recentes incluem o uso de IA generativa para a criação de dados sintéticos, recurso que mitiga a escassez de amostras reais e viabiliza treinamentos mais robustos (Mahmud; Kim, 2024; Teoh *et al.*, 2024). Outras abordagens promissoras envolvem as *Physics-Informed Neural Networks* (PINN), que incorporam princípios físicos aos modelos computacionais, aumentando a precisão das previsões (Sidi, 2024). Paralelamente, os *Large Language Models* (LLMs) vêm sendo explorados como ferramentas de apoio à tomada de decisão, fornecendo informações rápidas e contextualizadas para equipes de resposta a emergências (Sidi, 2024).

Outro aspecto de crescente relevância é a interpretabilidade dos modelos. Técnicas como o *Local Interpretable Model-Agnostic Explanations* (LIME) permitem identificar e compreender os fatores que influenciaram uma decisão algorítmica, reforçando a transparência e a confiabilidade das previsões — especialmente em contextos críticos como a gestão de desastres (Raju *et al.*, 2025). A incorporação de métodos explicáveis nos fluxos de trabalho baseados em IA é, portanto, fundamental para assegurar que as soluções adotadas sejam não apenas tecnicamente eficientes, mas também compreensíveis e confiáveis para gestores, equipes de campo e tomadores de decisão. Dessa forma, a combinação entre alto desempenho preditivo e clareza interpretativa se consolida como um dos pilares para o uso responsável e eficaz da IA na mitigação e resposta a desastres.

3.1.2 Desastres Naturais: Classificação e Ciclo de Gestão


O século XXI tem sido caracterizado por um aumento significativo na frequência e intensidade dos desastres naturais, resultado direto do agravamento das mudanças climáticas globais e de pressões humanas sobre os ecossistemas (IPCC, 2014). Somente em 2023, foram registrados, em escala global, 392 eventos catastróficos de origem natural, resultando em perdas econômicas superiores a 250 bilhões de dólares. Entre esses episódios, destacam-se inundações ocasionadas por chuvas extremas e pelo transbordamento de rios, associadas a alterações no regime hidrológico e à impermeabilização do solo; incêndios florestais intensificados por ondas de calor e estiagens prolongadas; ciclones tropicais e tempestades severas potencializados pelo aquecimento anômalo das águas oceânicas; e deslizamentos de terra provocados pela saturação hídrica em encostas instáveis ou ocupadas de forma irregular (IPCC, 2022; ONU, 2023).

Esses eventos evidenciam a interação entre fatores naturais e ações antrópicas, como as mudanças climáticas globais, a urbanização desordenada, o desmatamento e a degradação ambiental, que contribuem para intensificar riscos e ampliar impactos socioeconômicos.

Segundo o *United Nations Office for Disaster Risk Reduction* (UNDRR), a classificação dos desastres naturais pode ser realizada de acordo com a natureza do fenômeno desencadeador, contemplando as seguintes categorias:

- **Hidrometeorológicos** – chuvas extremas, inundações, ciclones, tempestades severas e secas;
- **Geofísicos** – terremotos, erupções vulcânicas e movimentos de massa, como deslizamentos e avalanches;
- **Biológicos** – epidemias, surtos zoonóticos e pragas que afetam ecossistemas e populações humanas.

Figura 1 - Categorias de desastres naturais e seus principais eventos. Classificação dos desastres naturais em categorias geofísicos, hidrológicos, meteorológicos, climatológicos, biológicos e extraterrestres, com respectivos eventos e perigos associados.



Fonte: Adaptado de Chaudhary e Piracha (2021).

De acordo com a *Classificação e Codificação Brasileira de Desastres – COBRADE* (Brasil, 2012), os desastres de origem tecnológica abrangem diferentes tipos de ocorrências. Entre elas estão os acidentes envolvendo substâncias radioativas, produtos perigosos, incêndios

urbanos, falhas em obras civis e eventos relacionados ao transporte de passageiros ou de cargas, independentemente de serem perigosas ou não. (CIVIL, 2017).

A gestão de desastres é tradicionalmente estruturada em quatro fases interdependentes:

- **Prevenção** – voltada à redução de riscos e vulnerabilidades;
- **Mitigação** – destinada a minimizar os impactos inevitáveis;
- **Resposta** – que concentra ações emergenciais imediatas;
- **Recuperação** – voltada à restauração das condições normais e ao fortalecimento da resiliência comunitária.

Essas fases são destacadas por organismos nacionais e internacionais como essenciais para um sistema eficaz de proteção e defesa civil (UNDRR, 2017).

3.1.3 Agenda 2030 e o ODS 11

A Agenda 2030 para o Desenvolvimento Sustentável, instituída pela Organização das Nações Unidas (ONU) em 2015, estabelece 17 Objetivos de Desenvolvimento Sustentável (ODS) que orientam ações globais para a construção de sociedades mais inclusivas, resilientes e ambientalmente equilibradas (Brasil; ONU, 2025). No contexto desta pesquisa, destaca-se o **ODS 11 – Tornar as cidades e os assentamentos humanos inclusivos, seguros, resilientes e sustentáveis**, diretamente relacionado à prevenção e mitigação de desastres naturais (IPEA, 2024).

Entre as metas do ODS 11, duas se mostram particularmente relevantes para este estudo:

- **Meta 11.5** – Reduzir significativamente, até 2030, o número de mortes, de pessoas afetadas e as perdas econômicas decorrentes de desastres, incluindo os relacionados à água, com foco na proteção de populações vulneráveis (Brasil; ONU, 2025).
- **Meta 11.b** – Ampliar substancialmente o número de cidades e assentamentos humanos que adotam e implementam políticas e planos integrados de mitigação e adaptação às mudanças climáticas, alinhados ao Marco de Sendai para a Redução de Riscos de Desastres 2015-2030 (Brasil; ONU, 2025).

Segundo relatório do IPEA (IPEA, 2024), o Brasil apresenta avanços pontuais nessas metas, mas ainda enfrenta desafios estruturais relevantes, como déficit habitacional, carência de infraestrutura urbana adequada, exposição de populações vulneráveis a áreas de risco e insuficiência de políticas públicas integradas para prevenção e resposta a eventos extremos. O documento aponta, ainda, que as regiões Norte e Nordeste concentram os menores índices de adoção de estratégias locais de redução de risco, reforçando a desigualdade territorial na capacidade de enfrentamento a desastres.

Nesse cenário, a aplicação de ferramentas de Inteligência Artificial (IA) adquire relevância estratégica, pois pode apoiar diretamente o alcance das metas do ODS 11 por meio do mapeamento de áreas de risco, da previsão de eventos extremos e do suporte à tomada de decisão em políticas urbanas e ambientais (Singh *et al.*, 2023; Raju *et al.*, 2025). A utilização integrada de dados climáticos, geoespaciais e socioeconômicos, combinados a modelos preditivos e classificatórios, contribui para ampliar a resiliência urbana e otimizar a alocação de recursos, alinhando os avanços tecnológicos às diretrizes globais de desenvolvimento sustentável (IPEA, 2024; Raju *et al.*, 2025).

3.2 Aplicações da Inteligência Artificial na Gestão de Desastres Naturais

A adoção de soluções baseadas em Inteligência Artificial (IA) para a gestão de desastres naturais tem evoluído de forma expressiva, impulsionada pela capacidade de processar grandes volumes de dados provenientes de sensores, imagens de satélite, equipamentos como drones e informações em tempo real. De maneira geral, essas aplicações se organizam em três frentes principais:

1. **Modelos preditivos** – voltados para antecipar eventos extremos;
2. **Modelos classificatórios** – que identificam e categorizam ocorrências;
3. **Análise geoespacial integrada ao sensoriamento remoto** – fundamental para o mapeamento de riscos e avaliação de danos.

Estudos recentes reforçam a diversidade dessas aplicações. (Mahmud; Kim, 2024) desenvolveram o *ATR HarmoniSAR*, um sistema capaz de gerar imagens sintéticas realistas para treinar modelos de detecção de vítimas em cenários de colapso estrutural, superando a escassez de dados reais e aumentando significativamente a precisão de identificação. (Teoh *et al.*, 2024)

exploraram o uso de IA generativa para criar conjuntos de imagens de enchentes e treinar modelos de detecção de objetos, otimizando o reconhecimento de áreas afetadas e a contagem de construções impactadas. (Rahnemoonfar *et al.*, 2021) apresentaram o *FloodNet*, um conjunto de imagens aéreas de alta resolução coletadas após inundações, destinado a treinar algoritmos para segmentação e análise de danos. Já (Raju *et al.*, 2025) propuseram o *GeoDisasterAINet*, um *framework* de classificação de desastres urbanos e rurais que combina redes neurais convolucionais, técnicas de aprendizado de máquina e explicabilidade via LIME, garantindo alta acurácia e interpretabilidade.

No Brasil, iniciativas como o **Projeto Noah**, desenvolvido pelo Instituto Metrópole Digital da Universidade Federal do Rio Grande do Norte (UFRN), mostram o potencial das ferramentas de IA para a comunicação e gestão de riscos. A plataforma conta com um chatbot que conecta cidadãos e Defesa Civil, permitindo o envio de informações sobre áreas afetadas, o que auxilia no direcionamento rápido de equipes e recursos.

No cenário internacional, o **Projeto Loon**, criado pela Alphabet, destacou-se pela aplicação de IA no controle de balões estratosféricos para fornecer internet a regiões isoladas ou atingidas por desastres. Durante os furacões em Porto Rico, em 2017, o sistema reestabeleceu a conectividade para milhões de pessoas, demonstrando como soluções inteligentes podem reforçar a resiliência das redes de comunicação em situações críticas.

Os exemplos apresentados, juntamente com as contribuições dos estudos analisados, mostram que a aplicação de ferramentas de Inteligência Artificial, quando integrada de forma consistente às políticas de prevenção, mitigação e resposta, tem capacidade de transformar a gestão de desastres. Além de ampliar a previsão e a detecção de riscos, essas tecnologias permitem otimizar recursos, apoiar decisões estratégicas em tempo real e, sobretudo, contribuir para salvar vidas, reduzir prejuízos e tornar mais ágil o processo de recuperação.

3.3 Modelos Preditivos

As ferramentas da Inteligência Artificial (IA) têm desempenhado papel cada vez mais central no desenvolvimento de modelos preditivos voltados à prevenção e mitigação de desastres naturais. Entre elas, destacam-se o *machine learning* (ML) e o *deep learning* (DL), capazes de identificar padrões complexos em grandes volumes de dados e oferecer previsões com elevada rapidez e precisão. Enquanto o ML abrange técnicas estatísticas e probabilísticas que possibilitam a classificação e a regressão em cenários diversos, o DL, por meio de redes

neurais artificiais de múltiplas camadas, tem se mostrado particularmente eficiente na análise de dados visuais, geoespaciais e ambientais (Artaxo; Rizzo; Machado, 2024; IPCC, 2023).

Ferramentas específicas vêm sendo aplicadas em diferentes contextos. No caso da previsão de enchentes, modelos desenvolvidos pelo *Google Flood Forecasting* utilizam algoritmos de ML combinados com dados hidrológicos, possibilitando alertas antecipados e de maior precisão em países como Índia e Bangladesh (Voosen, 2023). Já no monitoramento de terremotos, a *Japan Meteorological Agency* aplica redes neurais profundas para analisar sinais sísmicos iniciais, emitindo avisos com segundos de antecedência que têm permitido salvar vidas em situações críticas (Chen *et al.*, 2023).

Outros exemplos incluem modelos de previsão de furacões, como o *GraphCast*, do Google DeepMind, e o *Pangu-Weather*, da Huawei, que combinam redes neurais avançadas com grandes bases de dados climáticos. Essas ferramentas têm alcançado resultados superiores aos métodos convencionais, refinando a projeção de trajetória e intensidade de ciclones tropicais (Lam *et al.*, 2023). Além disso, algoritmos aplicados em sensoriamento remoto e imagens de satélite têm sido fundamentais na prevenção de deslizamentos e no monitoramento de incêndios florestais, permitindo identificar áreas de risco iminente e apoiar decisões estratégicas de gestão (Dalagnol *et al.*, 2023; Ball *et al.*, 2022).

Portanto, observa-se que as ferramentas da Inteligência Artificial, quando aplicadas em modelos preditivos, representam avanços decisivos para a gestão de riscos ambientais. Sua capacidade de integrar dados heterogêneos, extrair padrões complexos e oferecer previsões explicáveis reforça o potencial da IA como suporte estratégico para políticas de adaptação e resiliência frente às mudanças climáticas.

3.4 Modelos Classificatórios

Os modelos classificatórios têm um papel fundamental na gestão de desastres naturais. Eles são responsáveis por identificar padrões, categorizar eventos e diferenciar tipos específicos de ocorrências, como inundações, ciclones, terremotos e incêndios florestais (Raju *et al.*, 2025). Esse tipo de abordagem é essencial porque possibilita agir de forma mais direcionada, alocando recursos de maneira eficiente e auxiliando na tomada de decisão, principalmente em situações que exigem respostas rápidas.

Na literatura recente, o modelo *GeoDisasterAINet* tem ganhado destaque por reunir diferentes técnicas em um *framework* de *deep ensemble learning*. Essa proposta integra Redes Neurais Convolucionais (CNNs), responsáveis pela extração de padrões visuais, o algoritmo

XGBoost, utilizado no tratamento de dados estruturados e não estruturados, e o classificador *Multiclass SVM*, que contribui para aprimorar a separação entre classes. Um diferencial importante do *GeoDisasterAINet* é a incorporação da técnica LIME, que torna possível interpretar as decisões do modelo ao indicar quais características ou regiões da imagem tiveram maior influência no processo de classificação. Essa dimensão interpretativa é especialmente relevante em cenários críticos, como a gestão de desastres, em que não basta que o sistema apresente bons resultados — é igualmente essencial compreender os motivos que sustentam cada decisão gerada pelo modelo.

Outros modelos também têm se destacado nesse tipo de aplicação. A família *EfficientNet*, por exemplo, é bastante usada para classificação de imagens de satélite, conseguindo um bom equilíbrio entre desempenho e custo computacional (Tan; Le, 2019). As *ResNet* também são muito utilizadas, pois permitem treinar redes profundas sem sofrer tanto com a perda de desempenho causada pelo problema do gradiente, sendo aplicadas para identificar padrões de enchentes, queimadas e movimentos de massa (He *et al.*, 2016). Já as *DenseNet* aproveitam conexões densas entre camadas, o que facilita o reaproveitamento das informações e reduz o número de parâmetros, mantendo a eficiência mesmo em bases de dados mais complexas (Huang *et al.*, 2017).

Quando a demanda é por rapidez, como no monitoramento em tempo real, os modelos da família YOLO (*You Only Look Once*) são bastante vantajosos, pois conseguem detectar e classificar objetos de forma simultânea em imagens ou vídeos, mantendo alta velocidade de processamento (Redmon *et al.*, 2016).

No fim das contas, não existe um modelo único que seja perfeito para todas as situações. A escolha vai depender do tipo de dado que temos, da qualidade desse dado, dos recursos computacionais disponíveis e da urgência de aplicação. Muitas vezes, vale a pena combinar diferentes técnicas, como nos métodos *ensemble*, e investir em interpretabilidade, usando ferramentas como o LIME ou o SHAP. Isso garante que as soluções sejam não só eficientes, mas também confiáveis e úteis para quem precisa tomar decisões em campo.

3.5 Análise Geoespacial e Sensoriamento Remoto

A análise geoespacial integrada ao sensoriamento remoto tem se destacado como uma das áreas em que a Inteligência Artificial (IA) vem promovendo avanços significativos na gestão de desastres naturais. O uso de dados obtidos por satélites, veículos aéreos não tripulados (VANTs) e sensores terrestres possibilita o mapeamento, o monitoramento e a avaliação

detalhada de áreas afetadas, permitindo uma compreensão mais precisa da extensão e da gravidade dos impactos (Rahnemoonfar *et al.*, 2021; Li *et al.*, 2020).

Drones equipados com câmeras ópticas, sensores térmicos e tecnologia LIDAR têm sido empregados para gerar modelos tridimensionais de regiões de difícil acesso, identificar vítimas, localizar pontos de risco e avaliar danos estruturais em tempo quase real. Em áreas de alta periculosidade, robôs autônomos controlados por IA têm se mostrado alternativas viáveis, reduzindo a necessidade de exposição direta de equipes humanas a situações de risco (Li *et al.*, 2020).

A integração de sensores da *Internet of Things* (IoT) a sistemas inteligentes expande ainda mais essas possibilidades. Equipamentos que medem parâmetros como umidade, pressão e temperatura alimentam modelos preditivos capazes de emitir alertas automáticos sempre que limites críticos são atingidos, favorecendo a adoção de medidas preventivas antes que a situação se agrave (Shukla *et al.*, 2021).

Nesse contexto, merece destaque o *FloodNet*, um conjunto de dados elaborado a partir de imagens aéreas de alta resolução obtidas por VANTs após enchentes severas nos Estados Unidos. Voltado ao avanço das pesquisas em visão computacional, o *FloodNet* disponibiliza imagens rotuladas que possibilitam o treinamento de algoritmos capazes de identificar áreas alagadas, estimar danos em infraestruturas e acompanhar a evolução do cenário pós-desastre. Mais do que um simples repositório de dados, trata-se de uma base estruturada para apoiar o desenvolvimento de soluções tecnológicas que tornam as ações de resposta e recuperação mais rápidas, precisas e fundamentadas (Rahnemoonfar *et al.*, 2021).

3.6 Discussão da Literatura

A revisão da literatura mostra que a Inteligência Artificial tem se consolidado como uma ferramenta essencial na gestão de desastres naturais. Os estudos analisados apontam avanços expressivos, desde modelos preditivos de eventos extremos até sistemas de classificação explicável e recursos de análise geoespacial. No entanto, também revelam que os desafios permanecem: a escassez de dados de qualidade, a dificuldade de interpretar modelos complexos e a necessidade de adaptar os resultados a situações reais ainda limitam a aplicação plena dessas tecnologias.

Nesse cenário, os quatro estudos selecionados para análise mais detalhada ilustram bem essas potencialidades e limitações. O *ATR HarmoniSAR* (Mahmud; Kim, 2024) responde à falta de dados em operações de busca e resgate, gerando imagens sintéticas que permitem treinar

modelos para detecção de vítimas em colapsos estruturais. O *FloodNet* (Rahnemoonfar *et al.*, 2021) contribui ao disponibilizar um conjunto robusto de imagens aéreas pós-enchente, viabilizando o desenvolvimento de algoritmos voltados à avaliação de danos e ao acompanhamento da evolução dos impactos. Já o *GeoDisasterAINet* (Raju *et al.*, 2025) propõe um *framework* inovador para classificação de desastres urbanos e rurais, combinando alto desempenho com interpretabilidade, aspecto essencial para garantir transparência e confiabilidade. Por fim, as pesquisas em IA generativa (Teoh *et al.*, 2024) oferecem uma alternativa promissora frente à escassez de dados reais, permitindo criar amostras sintéticas que fortalecem os processos de detecção e classificação em cenários de enchentes.

Esses trabalhos reforçam que os desafios não se resumem à escolha do algoritmo mais eficiente, mas envolvem a qualidade dos dados, a clareza das decisões automatizadas e a viabilidade de aplicação em situações reais. Ao mesmo tempo, abrem caminho para novas pesquisas que busquem integrar essas soluções a contextos específicos, como enchentes urbanas, deslizamentos em áreas de encosta e desastres de grande escala em regiões rurais. Dessa forma, a discussão evidencia tanto os avanços já conquistados quanto as lacunas que ainda precisam ser superadas. Ao aprofundar a análise dessas quatro abordagens, este trabalho pretende contribuir para uma compreensão mais clara das possibilidades e limitações da Inteligência Artificial aplicada à prevenção e mitigação de desastres naturais.

4 METODOLOGIA

4.1 Tipo de Pesquisa

A presente investigação caracteriza-se como uma pesquisa bibliográfica, exploratória e descritiva. É classificada como bibliográfica por se fundamentar na análise de estudos recentes que abordam a aplicação de Ferramentas de Inteligência Artificial (IA) na prevenção e mitigação de desastres naturais, reunindo, organizando e interpretando contribuições já publicadas sobre o tema. Assume natureza exploratória ao buscar ampliar a compreensão sobre os avanços e limitações identificados na literatura, permitindo o mapeamento crítico de tendências e lacunas existentes. Por fim, apresenta caráter descritivo, uma vez que sistematiza e compara os resultados obtidos nos trabalhos analisados, destacando suas contribuições e desafios para a consolidação da IA como ferramenta de apoio à gestão de riscos e emergências.

4.2 Seleção dos Estudos

A escolha dos estudos considerados nesta pesquisa foi guiada por três critérios fundamentais: relevância científica, atualidade e diversidade metodológica. O objetivo foi reunir trabalhos que não apenas representassem avanços significativos no campo da Inteligência Artificial aplicada à gestão de desastres, mas que também oferecessem perspectivas complementares em termos de desafios enfrentados e soluções propostas.


Nesse contexto, foram selecionados quatro estudos técnicos de referência e um artigo conceitual que servem como base para a discussão. O *ATR HarmoniSAR* (Mahmud; Kim, 2024) propõe o uso de dados sintéticos harmonizados para suprir a escassez de imagens em operações de busca e resgate, sobretudo em cenários de colapso estrutural. O *FloodNet* (Rahnermoonfar *et al.*, 2021) inaugura uma base de dados em alta resolução voltada à avaliação de enchentes e à análise de danos pós-desastre, organizada para múltiplas tarefas de visão computacional. O *GeoDisasterAINet* (Raju *et al.*, 2025) apresenta um *framework* híbrido que combina redes neurais profundas, algoritmos de aprendizado de máquina e técnicas de interpretabilidade via LIME, conciliando desempenho e transparência. Por sua vez, Teoh *et al.* (2024) introduzem o *FloodIntel*, um *framework* que integra drones, imagens sintéticas geradas por *gen-AI* e modelos *YOLOv8* para resposta a inundações, alcançando métricas expressivas, como *mAP50* de 96,7

Complementarmente, o artigo de (Corchado, 2023) fornece a base conceitual necessária para integrar essas metodologias. O autor contextualiza o papel da IA na gestão de crises a partir

de uma perspectiva histórica, recuperando lições dos chamados “invernos da IA” e destacando a relevância da IA generativa como tecnologia de ruptura. Além disso, reforça a necessidade de princípios éticos e de governança, como transparência, responsabilidade e prestação de contas, para que a aplicação dessas ferramentas em cenários críticos seja legítima e confiável.

Assim, a seleção desses trabalhos reflete a preocupação em contemplar desde problemas estruturais, como a falta de dados reais, até questões de aplicabilidade prática e interpretabilidade dos modelos, compondo um arcabouço metodológico sólido e abrangente para as análises desenvolvidas nas seções seguintes.

Figura 2 - Fluxograma de síntese dos estudos analisados. Representação esquemática dos quatro estudos selecionados (ATR HarmoniSAR, FloodNet, GeoDisasterAINet e Teoh et al., 2024) e suas principais técnicas associadas.



Fonte: Elaborado pelo autor (2025).

O *ATR HarmoniSAR* (Mahmud; Kim, 2024) foi concebido para operações de busca e resgate em cenários de colapso estrutural. Embora não tenha sido aplicado diretamente em eventos reais, apresenta caráter experimental com foco na fase pós-desastre, visando suprir a falta de imagens em situações críticas.

O *FloodNet* (Rahnemoonfar *et al.*, 2021) teve aplicação prática em imagens aéreas do furacão Harvey, nos Estados Unidos, constituindo-se como uma base de dados pública para avaliação de enchentes e danos. Sua ênfase está no contexto pós-desastre, especialmente em análise de impacto e resposta.

O *GeoDisasterAINet* (Raju *et al.*, 2025) configura-se como um *framework* conceitual e híbrido, ainda sem aplicação localizada em campo. Seu diferencial está na possibilidade de uso tanto em cenários preventivos e preditivos, por meio da antecipação de riscos geológicos, quanto em análises pós-desastre, ao integrar desempenho e interpretabilidade dos modelos.

Por fim, o *FloodIntel* (Teoh *et al.*, 2024) foi implementado na Malásia, empregando imagens sintéticas geradas por *gen-AI* e drones em operações de detecção de áreas inundadas. A proposta se insere na fase pós-desastre, com foco em resposta rápida e otimização do resgate, alcançando métricas expressivas de precisão.

4.3 Procedimentos de Análise

A etapa de análise dos estudos selecionados será conduzida de maneira sistemática, buscando garantir consistência metodológica e rigor científico. Para tanto, definiu-se um procedimento estruturado em três fases complementares:

- (i) **Identificação do problema central:** em cada estudo, será delimitado o desafio específico que motivou o desenvolvimento da proposta, seja ele a escassez de dados, a necessidade de classificadores explicáveis ou a limitação de técnicas existentes para cenários complexos de desastres naturais;
- (ii) **Descrição das técnicas aplicadas:** caracterização detalhada das soluções apresentadas, incluindo o uso de Redes Neurais Convolucionais (CNNs), algoritmos de detecção de objetos (YOLO), modelos de interpretabilidade como o LIME, além de abordagens baseadas em Inteligência Artificial generativa para a síntese de dados;
- (iii) **Discussão dos resultados e limitações:** exame das evidências apresentadas pelos autores, contemplando tanto os avanços e contribuições para o estado da arte quanto as restrições metodológicas ou contextuais que ainda persistem.

4.4 Critérios de Comparação

A avaliação das técnicas adotadas neste trabalho será conduzida a partir de quatro dimensões principais:

- **Aspectos técnicos** – métricas como acurácia, precisão, *recall* e custo computacional, indicadores que permitem mensurar a eficiência dos modelos;

- **Aspectos práticos** – aplicabilidade em situações reais, levando em conta tempo de resposta, robustez frente a dados ruidosos e infraestrutura tecnológica exigida;
- **Aspectos contextuais** – adequação às condições de países em desenvolvimento, nos quais são recorrentes limitações de recursos, disponibilidade de dados e infraestrutura computacional;
- **Aspectos interpretativos** – nível de transparência e explicabilidade dos modelos, requisito essencial para a confiabilidade das previsões e aceitação das ferramentas por gestores e tomadores de decisão.

Como recurso complementar, serão utilizados gráficos comparativos e esquemas conceituais que sintetizem vantagens e limitações observadas em cada dimensão, favorecendo uma análise mais clara e integrada.


4.5 Aprofundamento nas Técnicas Seleccionadas

4.5.1 Aprofundamento Crítico em ATR HarmoniSAR (Mahmud *et al.*, 2024)

O *ATR HarmoniSAR* foi projetado para solucionar um dos maiores gargalos da detecção automática de vítimas em cenários de desastre: a falta de dados adequados para treinar modelos de *deep learning*. Esse obstáculo surge tanto por limitações éticas quanto práticas, já que a coleta de imagens reais de vítimas em situações extremas é inviável. Modelos de detecção convencionais, como os treinados no COCO Dataset, apresentam desempenho insatisfatório nesses contextos, pois as vítimas aparecem parcialmente ocultas, cobertas por poeira ou misturadas visualmente aos escombros.

A proposta central do sistema é a geração de dados sintéticos realistas para treinamento supervisionado de redes neurais de detecção. O pipeline do ATR HarmoniSAR compreende as seguintes etapas principais:

Figura 3 - Fluxo de processamento do sistema ATR HarmoniSAR.




Fonte: Mahmud e Kim (2024).

4.5.1.1 Seleção e síntese de foreground (vítimas)


Na geração das vítimas sintéticas, emprega-se o módulo *ImageMixer*, construído a partir da arquitetura *MixNMatch*, por sua vez extensão do *FineGAN*. O mecanismo combina atributos (pose, forma, textura) para criar pessoas em situações variadas e próximas da realidade, reduzindo a dependência de dados reais e ampliando a diversidade do conjunto de treinamento (Mahmud; Kim, 2024).

Figura 4 - Interface do sistema ATR HarmoniSAR e exemplo de geração/harmonização de imagens sintéticas.



Fonte: Mahmud e Kim (2024)

Figura 5 - Arquitetura do módulo ImageMixer (baseado em FineGAN).




Fonte: Mahmud e Kim (2024)

4.5.1.2 Geração de máscaras e recorte poligonal

As figuras humanas (inteiras ou parciais) são recortadas e convertidas em máscaras binárias para delinear contornos com precisão, permitindo integração natural ao *background* e evitando artefatos visuais comuns de recortes simples (Mahmud; Kim, 2024).

Figura 6 - Exemplo de geração de máscaras: (a) seleção dos contornos; (b) máscara



Fonte: Mahmud e Kim (2024)

4.5.1.3 3. Seleção de backgrounds (cenários de desastre)

Foram utilizados múltiplos cenários reais (terremotos, colapsos estruturais), contemplando variações de escombros, texturas e iluminação, para robustez do treinamento (Mahmud; Kim, 2024).

Figura 7- Exemplos de cenários de desastre usados como background.




Fonte: Mahmud e Kim (2024)

4.5.1.4 Composição e harmonização (Poisson Image Editing)

O diferencial do ATR HarmoniSAR é a harmonização entre *foreground* e *background* por meio de *Poisson Image Editing*: suavização de bordas e equalização de cor/iluminação/texture, resolvendo uma equação de Poisson com condições de contorno (aplicada por canal RGB) (Mahmud; Kim, 2024). O resultado é uma composição realista, superior ao simples *cut-and-paste*.

Figura 8 - Esquema da interpolação guiada pela equação de Poisson na harmonização.



Fonte: Mahmud e Kim (2024)

4.5.1.5 5. Geração automática de rótulos

Após a harmonização, um módulo de anotação produz *bounding boxes* das vítimas, acelerando a preparação do *dataset* (Mahmud; Kim, 2024).


4.5.1.6 6. Treinamento supervisionado (*fine-tuning*)

Utiliza-se o YOLOv5x (*one-stage detector*) pela boa relação velocidade–acurácia. O modelo pré-treinado em COCO recebe *fine-tuning* com o *ATR 1k Victim Dataset* (1,000 imagens harmonizadas), especializando-se em vítimas parcialmente visíveis em ambientes caóticos (Mahmud; Kim, 2024).

4.5.1.7 7. Avaliação e métricas

A métrica principal é AP50 (IoU=0,5). Reporta-se ganho de **29,3% para 92,4%** em AP50 no YOLOv5x após uso do *dataset* harmonizado, evidenciando a eficácia da abordagem (Mahmud; Kim, 2024). Outras arquiteturas (Faster R-CNN, SSD MobileNetV2) também apresentaram ganhos relevantes.

Figura 9 - Matrizes de confusão e curvas precisão–revocação dos detectores treinados no ATR 1k Victim Dataset.



Fonte: Adaptado de Mahmud e Kim (2024).

Figura 10 - Comparação: recorte direto (cut-and-paste) vs. harmonização por Poisson.



Fonte: Mahmud e Kim (2024).

4.5.1.8 Síntese quantitativa

Tabela 1 - Comparação de desempenho dos detectores treinados no COCO e com imagens

Modelo	Params (M)	Velocidade (FPS)	Treinado no COCO		Imagens Harmonizadas		
			AP	AP50	+ΔAP	AP	+ΔAP50
YOLOv5s	7.2	192	10.4	35.7	(+25.3)	15.2	(+30.9)
YOLOv5m	21.2	128	13.3	48.3	(+35.0)	18.9	(+46.1)
YOLOv5l	46.5	82	17.5	59.2	(+41.7)	23.2	(+54.2)
YOLOv5x	86.7	45	22.7	67.9	(+45.2)	29.3	(+63.1)
Faster R-CNN ViTDet Tiny	22.9	96	18.3	60.9	(+42.4)	23.6	(+50.2)
MobileNetV2 SSD	15	316	8.2	31.6	(+23.4)	10.5	(+16.5)

Fonte: Adaptado de Mahmud, Fime e Kim (2024)

A Tabela 1 apresenta o número de parâmetros, a velocidade de inferência (FPS) e as métricas de precisão média (AP) e precisão média com IoU $\geq 0,5$ (AP₅₀). Observa-se que, em todos os modelos, houve ganho significativo após o uso do *dataset* harmonizado, com destaque para o YOLOv5x, que atingiu AP₅₀ de 92,4%.

4.5.1.9 9. Limitações e desafios

Persistem desafios: coleta de dados reais inviável; inconsistências visuais nos métodos iniciais de composição; baixa luminosidade e forte oclusão; e o equilíbrio entre falsos positivos/negativos (com ênfase na redução de falsos negativos em missões de resgate). Avanços adicionais são necessários tanto na geração de dados quanto na robustez dos detectores (Mahmud; Kim, 2024).

4.5.1.10 Recursos computacionais

O desenvolvimento foi descrito com ambiente de alto desempenho (*e.g.*, Ubuntu 20.04, GPU NVIDIA RTX A6000), implementação em PyTorch e detectores YOLOv5 (principal),

Faster R-CNN (ViTDet Tiny) e SSD MobileNetV2 (comparativos). A classe *person* do COCO 2017 serviu como base para derivar o *ATR 1k Victim Dataset*. Avaliações consideraram AP, AP50, matrizes de confusão e curvas precisão–revocação (Mahmud; Kim, 2024).

4.5.2 Aprofundamento Crítico em FloodNet (Rahnemoonfar *et al.*, 2021)

A avaliação de danos após desastres naturais é fundamental para orientar ações rápidas e eficazes de resposta. Entretanto, esse processo tem sido historicamente limitado pela baixa resolução das imagens de satélite e pela inconsistência dos dados provenientes de redes sociais. Nesse cenário, o *FloodNet* representa uma contribuição relevante, ao disponibilizar o primeiro conjunto público de imagens aéreas de alta resolução capturadas por drones, acompanhado de anotações detalhadas para diferentes tarefas de visão computacional (Rahnemoonfar *et al.*, 2021).

O diferencial do *FloodNet* está em sua capacidade de suportar múltiplas aplicações, como classificação de imagens, segmentação semântica e *Visual Question Answering* (VQA), a partir de um mesmo conjunto de dados. Essa versatilidade amplia seu valor tanto para a pesquisa acadêmica quanto para o desenvolvimento de soluções práticas na gestão de emergências (Rahnemoonfar *et al.*, 2021).

Os testes realizados com modelos de referência mostraram resultados promissores, mas também revelaram desafios, sobretudo na detecção de objetos pequenos e em tarefas de raciocínio mais complexo, como a contagem de elementos em cena. Ainda assim, o *FloodNet* estabelece um marco para a área, oferecendo uma base sólida para novas investigações e para a criação de sistemas mais robustos e eficazes no apoio a operações de resgate (Rahnemoonfar *et al.*, 2021).

O *FloodNet* foi concebido para suprir lacunas críticas na avaliação de danos pós-desastre. Esse *dataset* inaugura um paradigma inovador ao disponibilizar imagens aéreas de alta resolução capturadas por veículos aéreos não tripulados (VANTs), acompanhadas de anotações detalhadas em nível de pixel. Sua principal contribuição está no caráter pioneiro, sendo o primeiro conjunto de dados voltado simultaneamente para três tarefas de visão computacional: classificação, segmentação semântica e VQA (Rahnemoonfar *et al.*, 2021).

A utilização de VANTs possibilita a coleta de imagens em baixa altitude, garantindo uma clareza muito superior à das imagens de satélite e uma consistência inexistente nos registros de redes sociais. Essa qualidade visual é crucial para que modelos de *deep learning* consigam identificar, com precisão, detalhes complexos do cenário pós-inundação, como áreas

alagadas, veículos e condições de estradas e edificações. Além disso, por ser de acesso público, o *FloodNet* elimina barreiras de custo de aquisição e rotulagem, consolidando-se como um recurso acessível e estratégico para pesquisadores e profissionais da área de Inteligência Artificial (Rahnemoonfar *et al.*, 2021).

Tabela 2 - Comparação entre diferentes datasets utilizados em visão computacional

Dataset	Types of Images	UAV imagery	Post Disaster	Resolution of Images	Classification	Semantic Segmentation	VQA
ImageNet	Real-world images	No	No	average 400x350	7	7	7
Cityscapes	Real-world images	No	No	1280x720	3	3	7
DAQUAR	Real-world images	No	No	640x480	7	7	3
COCO-QA	Real-world images	No	No	640x480	7	7	3
COCO-VQA	Real-world images, abstract cartoon images	No	No	640x480	7	7	3
Visual Genome	Real-world images	No	No	varies in size	3	3	3
Visual7W	Real-world images	No	No	varies in size	7	7	3
TDIUC	Real-world images	No	No	varies in size	7	7	3
CLEVR	Geometrical Shape	No	No	320x240	7	7	3
PATHVQA	Medical Images	No	No	varies in size	7	7	3
VQA-MED	Medical Images	No	No	varies in size	7	7	3
Nguyen et al.	Post Disaster Images	No	Yes	varies in size	3	3	7
ABCD	Pre and Post Disaster Images	No	Yes	varies in size	3	7	7
SpaceNet + Deeplobe	Pre and Post Disaster Images	No	Yes	varies in size	3	7	7
Chen et al.	Post Disaster Images	No	Yes	varies in size	3	3	7
OSCD	Urban Change Images	No	Yes	varies in size	3	3	7
MDoW	Pre and Post Disaster Images	No	Yes	varies in size	3	3	7
AIDER	Post Disaster Images	Yes	Yes	varies in size	3	7	7
Rudner et al.	Post Disaster Images	Yes	Yes	varies in size	3	7	7
xBD	Pre and Post Disaster Images	No	Yes	varies in size	3	3	7
FloodNet (Ours)	Post Disaster Images	Yes	Yes	4000x3000	3	3	3

Fonte: Rahnemoonfar et al. (2021)

4.5.2.1 Aquisição dos dados e rotulagem

O *FloodNet* é um *dataset* de imagens aéreas de alta resolução criado após o furacão Harvey, que devastou o Texas e a Louisiana em 2017. As imagens foram coletadas com drones DJI Mavic Pro em áreas gravemente atingidas no Condado de Ford Bend, entre 30 de agosto e 4 de setembro, a uma altitude de 200 pés (cerca de 61 metros). Essa estratégia metodológica possibilitou capturas com resolução aproximada de 1,5 cm/pixel, garantindo um nível de detalhamento muito superior ao de imagens de satélite e permitindo identificar com clareza estradas, edificações e veículos.

A etapa de anotação também foi criteriosa: 2.343 imagens foram rotuladas manualmente em nove classes (*building-flooded*, *building-non-flooded*, *road-flooded*, *road-non-flooded*, *water*, *tree*, *vehicle*, *pool* e *grass*) por meio de segmentação pixel a pixel na plataforma V7 Darwin. Cada anotação passou por revisão dupla e exigiu, em média, uma hora de trabalho, assegurando consistência e qualidade elevada.

O *dataset* foi estruturado para três tarefas principais: classificação (com base no percentual de área inundada), segmentação semântica (com rotulagem de cada pixel nas nove classes) e *Visual Question Answering* (VQA), que reúne cerca de 4.500 pares de pergunta-imagem. Apesar de seu caráter inovador, a distribuição das classes apresenta certo desequilíbrio, o que representa um desafio adicional para os modelos de aprendizado de máquina, mas ao mesmo tempo reforça o valor do *FloodNet* como base de pesquisa robusta e realista.

Tabela 3 - Quantidade de imagens e instâncias por classe no FloodNet.

Classe	Imagens	Instâncias
Building-flooded	245	3248
Building-non-flooded	880	3427
Road-flooded	264	495
Road-non-flooded	1175	2155
Vehicle	813	4535
Pool	531	1141
Tree	1885	19682
Water	984	1374

Fonte: Rahnemoonfar et al. (2021)

A Tabela 3 demonstra uma grande variabilidade nas instâncias, com a classe *tree* sendo a mais frequente, enquanto a classe *pool* é relativamente rara. Esse desequilíbrio nos dados de treinamento representa um desafio adicional para os modelos, que podem ter dificuldades em generalizar e detectar com precisão classes com poucas instâncias, como *pool* ou *road-flooded*.

4.5.2.1.1 Construção do dataset

Para garantir independência estatística e reduzir o risco de sobreajuste (*overfitting*), o *FloodNet* foi dividido em três subconjuntos — treino, validação e teste — aplicados de maneira consistente em todas as tarefas propostas. A proporção adotada foi de 70% das imagens para o treinamento e 30% destinadas à validação e ao teste, o que assegura comparabilidade entre experimentos e permite que o desempenho observado no conjunto de teste reflita de fato a capacidade de generalização dos modelos para dados não vistos.

4.5.2.2 Análise Profunda de Segmentação Semântica

A segmentação semântica, responsável por classificar cada pixel nas nove classes do *FloodNet*, constitui a base da análise detalhada de danos. Para essa tarefa, foram avaliados os modelos PSPNet, ENet e DeepLabV3+, representando diferentes arquiteturas de rede.

A principal métrica utilizada foi a média do *Intersection over Union* (mIoU) por classe, capaz de medir a precisão da sobreposição entre as predições e as anotações reais.

Tabela 4 - Tipos de perguntas e respostas possíveis no VQA do FloodNet.

Tipo de Pergunta	Respostas Possíveis
Simple Counting	{1, 2, 3, 4, ...}
Complex Counting	{1, 2, 3, 4, ...}
Condition Recognition	Flooded; Non-Flooded; Both Flooded & Non-Flooded
Yes/No-Type Question	Yes; No

Fonte: Rahneemoonfar et al., (2021)

Conjunto de respostas associadas a quatro tipos de questões: contagem simples, contagem complexa, reconhecimento de condição e perguntas do tipo sim/não.

4.5.2.2.1 Divisão em treino/validação/teste

As imagens foram divididas em 70% para treino e 30% para validação e teste, garantindo independência estatística e prevenindo sobreajuste (*overfitting*). Essa divisão foi aplicada de forma consistente para todas as tarefas (*classificação*, *segmentação* e VQA). Dessa forma, assegura-se comparabilidade entre experimentos e permite que o desempenho observado no conjunto de teste reflita de fato a capacidade de generalização dos modelos para dados não vistos.

Na tarefa de classificação binária, que diferencia imagens “inundadas” e “não inundadas”, os autores avaliaram três arquiteturas de *deep learning* amplamente consolidadas: InceptionNetV3, ResNet50 e Xception. Todas foram inicialmente pré-treinadas no *dataset* ImageNet e, posteriormente, ajustadas por meio de *fine-tuning* para o domínio específico da detecção de cenas de inundação. A principal métrica utilizada para mensurar o desempenho foi a acurácia global, parâmetro capaz de indicar a eficácia de cada modelo na correta identificação das classes.

Tabela 5 - Acurácia de classificação no FloodNet.

Modelo	Training	Validation	Test
InceptionNetV3	95.37%	92.89%	95.09%
ResNet50	93.99%	92.22%	93.30%
Xception	96.54%	96.00%	94.64%

Fonte: Rahnemoonfar *et al.* (2021)

A análise da Tabela 5 mostra que, embora as três arquiteturas tenham alcançado desempenhos elevados, o InceptionNetV3 se destacou com a melhor acurácia no conjunto de teste, atingindo 95,09%. Esse resultado contrasta com o observado em bases como o *ImageNet*, nas quais o ResNet50 costuma apresentar desempenho superior. A vantagem do InceptionNetV3 no *FloodNet* pode ser explicada por sua arquitetura em múltiplas escalas, que utiliza diferentes tamanhos de *kernel* para processar a entrada. Essa característica se mostra especialmente eficaz em imagens aéreas, nas quais convivem objetos de dimensões muito distintas, como edifícios de grande porte e veículos de pequeno porte, exigindo extração de padrões em diferentes resoluções.

Tabela 6 - Resultados de segmentação semântica no FloodNet (IoU por classe e mIoU).

Método	Building Flooded	Building Non Flooded	Road Flooded	Road Non Flooded	Water	Tree	Vehicle	Pool	Grass	mIoU
ENet	21.82	41.41	14.76	52.53	47.14	62.56	26.21	16.57	75.57	39.84
DeepLabv3+	28.10	78.10	32.00	81.10	73.00	74.50	33.60	40.00	87.10	58.61
PSPNet	65.61	90.92	78.69	90.90	91.25	89.17	54.83	66.37	95.45	80.35

Fonte: Rahnemoonfar et al. (2021)

Os resultados da Tabela 6 indicam que o PSPNet apresentou o melhor desempenho, com mIoU geral de 80,35%, superando os demais modelos. Ainda assim, persistem desafios importantes: classes com poucos exemplos e objetos pequenos, como *vehicle* e *pool*, tiveram os piores índices, refletindo a dificuldade em detectar instâncias reduzidas. Outro obstáculo foi a distinção entre categorias contextualmente semelhantes, como *building-flooded* e *building-non-flooded*, ou *road-flooded* e *road-non-flooded*, em que os modelos tiveram desempenho inferior nas versões inundadas.

4.5.2.3 Avaliação do Visual Question Answering (VQA)

No *FloodNet*, a tarefa de VQA avalia a capacidade dos modelos de integrar informações visuais e textuais para responder a perguntas sobre as imagens. Para esse fim, foram utilizados modelos *baseline*, como o *Stacked Attention Network* (SAN) e o *Multimodal Factorized Bilinear* (MFB) com co-atenção.

A Tabela 7 mostra que o VQA obteve alta acurácia em questões de reconhecimento de *Condição* e *Sim/Não*, superando 95%, mas apresentou desempenho muito inferior em tarefas de *Contagem*, raramente acima de 35%. Essa limitação está ligada às dificuldades já observadas na segmentação semântica, especialmente na detecção e individualização de objetos pequenos ou ambíguos. Assim, os modelos se mostram mais eficazes no raciocínio categórico do que no numérico e granular, evidenciando um desafio central para o avanço da IA em cenários de desastre.

Tabela 7 - Resultados do VQA no FloodNet

Modelo	Data Type	Overall Accuracy	Accuracy (Simple Counting)	Accuracy (Complex Counting)	Accuracy (Yes/No)	Accuracy (Condition Recognition)
Concatenation (79)	Validation	0.53	0.06	0.05	0.33	0.88
	Testing	0.52	0.06	0.03	0.31	0.88
Point-wise Multiplication (14)	Validation	0.77	0.32	0.29	0.95	0.96
	Testing	0.77	0.30	0.28	0.97	0.97
MFB with Co-Attention (74)	Validation	0.77	0.27	0.26	0.98	0.97
	Testing	0.74	0.21	0.21	0.98	0.96
SAN (63)	Validation	0.70	0.31	0.30	0.58	0.97
	Testing	0.71	0.32	0.32	0.62	0.96

Fonte: Rahnemoonfar et al. (2021)

4.5.2.4 Perspectivas e Recomendações para a Comunidade de Pesquisa

As pesquisas futuras podem explorar diferentes caminhos a partir do FloodNet, ampliando seu impacto na área de Inteligência Artificial aplicada à gestão de desastres. O desenvolvimento de arquiteturas que integrem *pyramid pooling* com mecanismos de atenção mais refinados surge como alternativa promissora para superar limitações na detecção de objetos pequenos e na diferenciação entre classes contextualmente próximas.

Técnicas como *few-shot learning* e *meta-learning* também se apresentam como soluções potenciais para lidar com o desequilíbrio de classes, especialmente em categorias menos representadas, como *pool*. Da mesma forma, avanços em modelos de fusão multimodal são fundamentais para elevar o desempenho das tarefas de Visual Question Answering (VQA), sobretudo em questões de contagem, que demandam a combinação precisa de representação visual e interpretação textual. Além disso, a incorporação de métodos de detecção de objetos em paralelo à segmentação pode representar um avanço relevante para a enumeração de instâncias em cenários complexos.

4.5.2.5 Ambiente Computacional

Os experimentos foram realizados em uma estação equipada com GPU NVIDIA RTX 2080 Ti e processador Intel Core i9, com implementação em PyTorch e TensorFlow. Para

segmentação, foram aplicadas técnicas de *data augmentation* (rotação, escala, inversão e recorte aleatório), o que reduziu o risco de *overfitting* e melhorou a generalização dos modelos.

4.5.2.6 Aprofundamento Crítico em GeoDisasterAINet (Raju et al., 2025)

O GeoDisasterAINet constitui um avanço metodológico na gestão de desastres ao propor um *framework* híbrido que combina redes neurais convolucionais (CNNs) para extração de características com algoritmos de aprendizado de máquina, como XGBoost e SVM multiclasse, responsáveis pelo refinamento da classificação. Essa integração foi projetada para superar limitações dos métodos convencionais, oferecendo maior generalização, rapidez e confiabilidade em cenários críticos.

Entre seus diferenciais, destaca-se a incorporação do LIME, que garante interpretabilidade e transforma o modelo em uma solução transparente e confiável, aspecto essencial para aplicações em situações de emergência. Além de seu desempenho robusto, o *framework* está alinhado às metas do ODS 11 da ONU, contribuindo para a construção de cidades e comunidades mais seguras e resilientes diante de eventos extremos.

O ODS 11 da ONU reforça a necessidade de cidades e comunidades seguras, resilientes e sustentáveis, com ênfase em infraestrutura adequada, gestão de desastres eficaz e processos ágeis de recuperação. Nesse contexto, o GeoDisasterAINet vai além de uma solução técnica, configurando-se como uma resposta estratégica a esse desafio global. Sua arquitetura híbrida, capaz de realizar classificações em tempo real com alta acurácia, contribui diretamente para suprir as limitações dos métodos tradicionais e apoia o alcance das metas do ODS 11, fortalecendo a resiliência urbana e rural frente a eventos extremos.

A confiabilidade do GeoDisasterAINet inicia-se no processo de aquisição e preparação dos dados. O estudo utilizou 4.428 imagens de desastres naturais obtidas de fontes públicas, distribuídas em quatro classes: ciclones (928), terremotos (1.350), enchentes (1.073) e incêndios florestais (1.077), evidenciando um desequilíbrio entre categorias.

Para garantir consistência com as arquiteturas de aprendizado profundo, todas as imagens foram redimensionadas para 224×224 pixels, convertidas para RGB, normalizadas e submetidas à remoção de ruídos, minimizando distorções que poderiam comprometer a extração de características.

Um ponto crítico foi o desbalanceamento de classes. Para enfrentá-lo, aplicou-se a técnica SMOTE (*Synthetic Minority Over-sampling Technique*) apenas ao conjunto de treinamento, mantendo intactos os conjuntos de validação (10%) e teste (15%). Essa decisão

metodológica assegurou que a avaliação refletisse o desempenho real do modelo em cenários naturalmente desequilibrados, evitando superestimação por dados sintéticos.

Tabela 8 - Distribuição do dataset utilizado no GeoDisasterAINet.

Split	Cyclone	Earthquake	Flood	Wildfire	Total
Training	1012	1012	1012	1012	4048
Testing	139	201	160	162	662
Validation	93	136	108	107	444
Total	1244	1349	1280	1281	4048

Fonte: Adaptado de Raju et al. (2025).

Com isso, obteve-se um conjunto de treinamento equilibrado em 1.012 imagens por classe (total de 4.048), enquanto os demais conjuntos permaneceram originais, preservando a robustez estatística e a confiabilidade da avaliação do GeoDisasterAINet.

Estágio 1 – CNNs Integradas

O primeiro estágio é responsável pela extração hierárquica de características a partir de imagens. Três *ensembles* foram explorados: o **ERI-2025** (EfficientNetB7, ResNet-50 e InceptionV3), que combina eficiência, conexões residuais e análise em múltiplas escalas; o **DRI-2025** (DenseNet-201, ResNet-50 e InceptionV3), que se destaca pela reutilização de *features* e robustez em padrões complexos; e o **DE-2025** (DenseNet-201 e EfficientNetB7), otimizado para eficiência computacional e classificação em tempo real.

Estágio 2 – Refinamento com XGBoost

No segundo estágio, as características extraídas pelas CNNs são refinadas pelo XGBoost, que atua como um filtro inteligente. O algoritmo seleciona os padrões mais relevantes e reduz o ruído, garantindo que apenas as *features* discriminativas sejam aproveitadas. Essa etapa aumenta a robustez do sistema e melhora a separação entre diferentes tipos de desastres.


Estágio 3 – Classificação com Multiclass SVM

Por fim, no terceiro estágio, os vetores otimizados pelo XGBoost passam por uma Máquina de Vetor de Suporte Multiclasse (SVM). O SVM constrói fronteiras de decisão precisas, essenciais para diferenciar desastres com características visuais semelhantes, como inundações e terremotos em áreas urbanas. Essa etapa finaliza o processo de classificação, assegurando maior generalização e confiabilidade dos resultados.

4.5.3 Arquitetura do Modelo Híbrido GeoDisasterAINet


No caso específico do ensemble **ERI-2025**, a arquitetura combina as redes *EfficientNet-B7*, *ResNet50* e *InceptionV3*. As saídas dessas redes são concatenadas, convertidas em vetor por uma camada de *reshape* e processadas em uma rede totalmente conectada, culminando na classificação final.

Figura 11 - Fluxo multiestágio do GeoDisasterAINet.



Fonte: Raju et al. (2025).

Figura 12 - Arquitetura do ensemble ERI-2025.



Fonte: Raju et al. (2025).

Figura 13 - Fluxograma Arquitetura GeoDisasterAINet.

Fluxograma Simplificado da Arquitetura GeoDisasterAINet



Fonte: Raju et al. (2025).

4.5.4 Avaliação de Desempenho: Uma Análise Quantitativa e Comparativa

4.5.4.1 Métricas e Metodologia de Avaliação

A avaliação do GeoDisasterAINet foi conduzida de forma rigorosa, com o uso de métricas consagradas em aprendizado supervisionado, como acurácia, precisão, recall, F1-score, curvas ROC e matrizes de confusão. O foco do estudo foi entender como cada componente da arquitetura híbrida contribuiu para o desempenho final, por meio de um estudo de ablação dividido em estágios sucessivos.

- **Estágio 1:** Nesse estágio foram avaliados individualmente os ensembles de CNNs (ERI-2025, DRI-2025 e DE-2025). Os modelos ERI-2025 e DE-2025 alcançaram bons resultados, com acurácia em torno de 94%, enquanto o DRI-2025 apresentou desempenho um pouco inferior (92%), revelando maior dificuldade em generalizar padrões mais complexos.
- **Estágio 2:** Nessa etapa a introdução do XGBoost trouxe ganhos significativos. Ao atuar como refinador das características extraídas pelas CNNs, o algoritmo aumentou a

acurácia de modelos como o ERI-2025+XGBoost e o DE-2025+XGBoost para 95,37%, confirmando seu papel como otimizador de *features* e redutor de ruídos.

- **Estágio 3:** O último estágio marcou o ponto alto da performance. A inclusão do Multiclass SVM permitiu ao modelo estabelecer fronteiras de decisão mais robustas, elevando a acurácia final para 96,37%. Esse resultado demonstra que a combinação de CNNs, XGBoost e SVM em um ensemble híbrido gera uma arquitetura mais estável, precisa e confiável para a classificação de cenários de desastres

A Tabela 9 resume o desempenho dos três estágios de avaliação do modelo híbrido, incluindo as métricas de acurácia de treino e teste, precisão, recall e F1-Score. Observa-se ganho incremental de desempenho com a adição do XGBoost e, posteriormente, do SVM Multiclasse, consolidando a superioridade da arquitetura em cascata.

Tabela 9 -Resultados do estudo de ablação do GeoDisasterAINet


Estágio do Experimento	Componentes Utilizados	Acurácia de (%) Treino	Acurácia de (%) Teste (%)	Precisão (%)	Recall (%)	F1-Score (%)
Estágio 1	CNNs Integradas	97 (ERI)	94 (ERI)	96 (ERI)	95 (ERI)	95 (ERI)
		95 (DRI)	92 (DRI)	94 (DRI)	93 (DRI)	94 (DRI)
		97 (DE)	94 (DE)	96 (DE)	95 (DE)	95 (DE)
Estágio 2	CNNs Integradas + XGBoost	98 (ERI)	95.37 (ERI)	97 (ERI)	96 (ERI)	96 (ERI)
		96 (DRI)	93.23 (DRI)	95 (DRI)	94 (DRI)	94 (DRI)
		98 (DE)	95.37 (DE)	97 (DE)	96 (DE)	96 (DE)
Estágio 3	CNNs + XGBoost + SVM	99 (ERI)	96.37 (ERI)	98 (ERI)	97 (ERI)	97 (ERI)
		97 (DRI)	93.80 (DRI)	96 (DRI)	95 (DRI)	95 (DRI)
		99 (DE)	95.50 (DE)	97 (DE)	96 (DE)	96 (DE)

Fonte: Adaptado de Raju et al. (2025).

4.5.4.2 O Modelo de Excelência: Análise Detalhada

O modelo **ERI-2025 + XGBoost + Multiclass SVM** se destacou como a melhor combinação, atingindo as seguintes métricas de teste: 96,37% de acurácia, 98% de precisão, 97% de *recall* e 97% de F1-score. Uma análise detalhada por classe no relatório de classificação revela a solidez do desempenho do modelo em cada tipo de desastre.

Figura 14 - Desempenho do GeoDisasterAINet no Estágio 3 (CNNs + XGBoost + SVM Multiclasse)




Fonte: Raju et al. (2025).

Tabela 10 - Métricas de desempenho por classe no GeoDisasterAINet (Estágio 3).

Classe	Precisão	Recall	F1-Score	Suporte
Ciclone	0.98	0.95	0.96	93
Terremoto	0.96	0.97	0.96	135
Enchente	0.94	0.95	0.94	107
Incêndio Florestal	0.97	0.96	0.97	109


Fonte: Adaptado de Raju et al. (2025).

Figura 15 - Matriz de confusão do modelo GeoDisasterAINet.



Fonte: Raju et al. (2025).

Figura 16 - Curvas ROC das quatro classes de desastres.




Fonte: Raju et al. (2025).

4.5.5 A Confiança da Transparência: Interpretabilidade com LIME

Em contextos críticos, a acurácia isolada não basta: é preciso compreender as razões por trás das previsões. O *GeoDisasterAINet* integra o LIME, ferramenta de Inteligência Artificial Explicável (XAI), que destaca as regiões da imagem que influenciam cada decisão. Assim,

padrões como nuvens em espiral (ciclones), áreas alagadas (enchentes), fumaça (incêndios) e escombros (terremotos) são evidenciados. Essa explicabilidade valida o modelo, reduz a percepção de “caixa preta” e transforma o sistema em um apoio confiável para gestores e equipes de emergências.

Figura 17 - Visualização LIME e Arquitetura do Ensemble GeoDisasterAINet



Fonte: Raju et al. (2025).

4.5.6 Ambiente Computacional

Outro ponto de destaque foi a infraestrutura computacional adotada, que combinou o uso de recursos em nuvem, com GPU NVIDIA T4 disponível no Google Colab Pro, a validações realizadas em hardware local. Essa estratégia demonstrou a viabilidade de aplicação tanto em ambientes de pesquisa quanto em cenários operacionais com restrições de recursos, garantindo maior flexibilidade e acessibilidade ao processo de desenvolvimento.

4.5.7 Considerações e Próximos Passos

O *GeoDisasterAINet* apresenta-se como uma contribuição significativa no campo da Inteligência Artificial aplicada à gestão de desastres, ao combinar o potencial das redes neurais convolucionais com o refinamento do XGBoost e a robustez do SVM Multiclasse em uma arquitetura integrada. Essa abordagem híbrida permitiu alcançar resultados expressivos em termos de precisão e generalização, ao mesmo tempo em que incorporou interpretabilidade por meio do LIME, elemento essencial para garantir confiabilidade em contextos de emergência.

No horizonte de evolução, o modelo pode ser expandido para novas categorias de desastres, integrando dados multimodais — como imagens de satélite, sensores e informações provenientes de redes sociais — e otimizando sua execução em dispositivos de

Edge AI, condição essencial para respostas rápidas em regiões com conectividade limitada. Ainda que a classificação de eventos já ocorridos não configure uma abordagem preditiva, ela desempenha papel relevante na resiliência ao possibilitar a identificação das áreas mais afetadas, a análise detalhada dos padrões de impacto e a priorização de recursos nas etapas de resposta e recuperação. Esse conhecimento retroalimentado fortalece a gestão de riscos e subsidia estratégias de mitigação, consolidando o *GeoDisasterAINet* como uma proposta inovadora, alinhada às metas do ODS 11 e voltada ao fortalecimento da resiliência urbana e comunitária.

4.6 Revisão Crítica do Artigo “Exploring Generative AI for YOLOBased Object Detection to Enhance Flood Disaster Response in Malaysia”

4.6.1 YOLOv8 e IA Generativa na Detecção de Inundações: Introdução e Contextualização

As inundações estão entre os desastres naturais mais recorrentes e impactantes no cenário global, com perdas econômicas que ultrapassam centenas de bilhões de dólares anualmente.

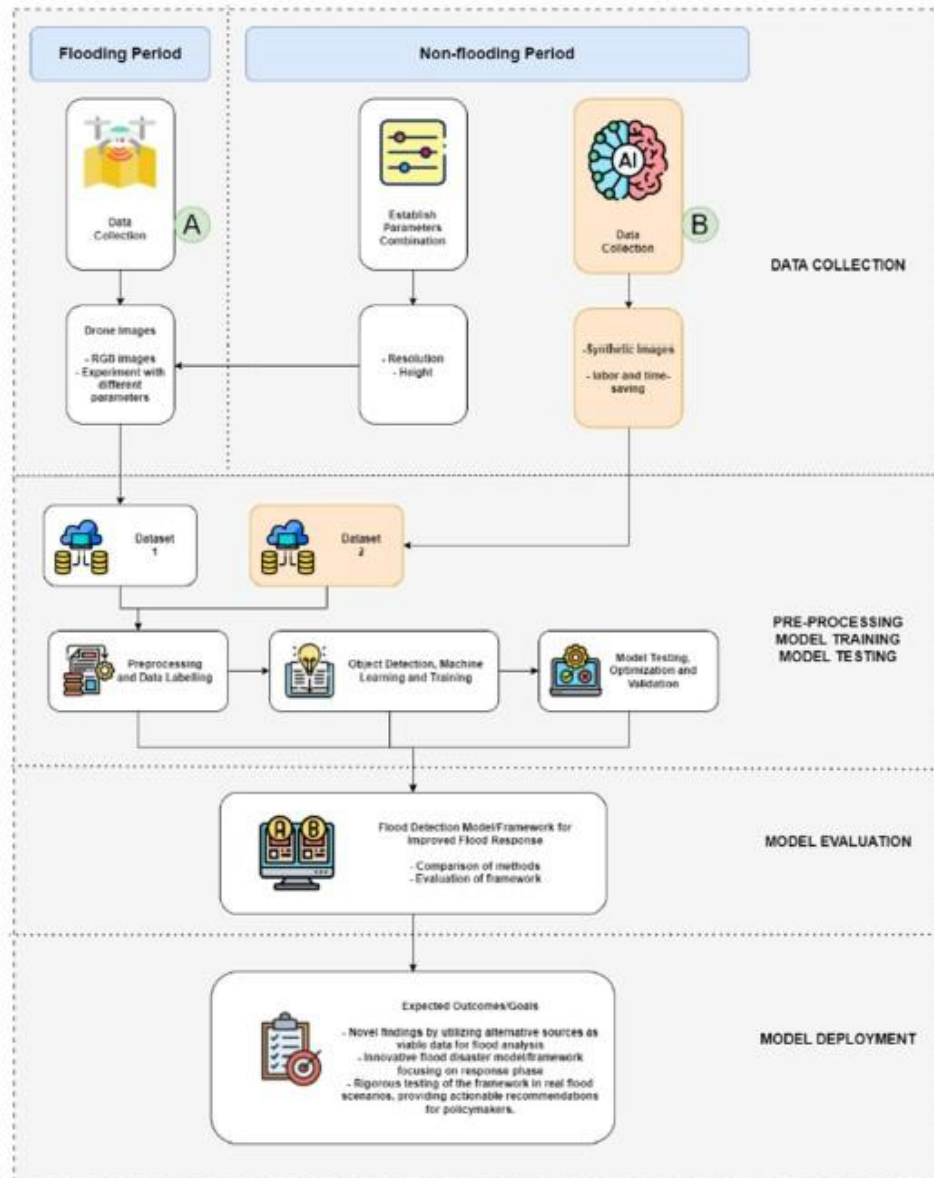
Na Malásia, esse cenário é particularmente grave, já que cerca de 60% das ocorrências de desastres naturais estão relacionadas a enchentes. Eventos históricos como a Grande Inundação de 1926 e a Grande Inundação Amarela de 2014, em Kelantan, evidenciam os danos socioeconômicos recorrentes que desafiam a capacidade de resposta do país.

Teoh *et al.* (2024) identificam lacunas críticas nos sistemas tradicionais de monitoramento, baseados em observação manual e imagens de satélite, que sofrem com limitações de resolução temporal e espacial, especialmente em áreas remotas. Nesse contexto, o artigo propõe o uso de inteligência artificial generativa (Gen-AI) para criar imagens sintéticas, utilizadas como fonte alternativa para o treinamento do modelo YOLO, a fim de melhorar a resposta a desastres.

4.6.2 O Framework FloodIntel

A principal contribuição teórica do estudo é o desenvolvimento do *framework* FloodIntel, que integra drones e modelos de inteligência artificial, visando otimizar a resposta a inundações por meio de detecção automática de áreas afetadas e estimativa de danos em tempo real. O framework propõe uma estratégia híbrida de dados: (i) dados reais coletados por drones durante eventos (Dados A) e (ii) dados sintéticos gerados em períodos de não-inundação (Dados B). Essa combinação busca garantir a preparação contínua do sistema.

Figura 18 - Estrutura do framework FloodIntel, combinando imagens reais e sintéticas para suporte à resposta em desastres.



Fonte: Teoh et al. (2024).

4.6.3 Construção e Preparação do Dataset Sintético

O conjunto de dados sintéticos foi produzido por meio de ferramentas como Freepik, Canva, Adobe Firefly e Flux AI. Após filtragem, foram obtidas 3.750 imagens que representavam cenários urbanos e rurais de enchentes na Malásia. As imagens foram padronizadas em perspectiva ortográfica (visão de drone), garantindo consistência operacional.


Cada imagem foi anotada manualmente no Roboflow, totalizando 43.023 objetos, com média de 11,5 por imagem. A Figura 19 mostra exemplos dessas anotações, e a Figura 20 apresenta a distribuição de objetos por imagem, predominando entre 2 e 15.

Figura 19 - Exemplos de imagens sintéticas anotadas com bounding boxes em telhados.



Fonte: Adaptado de Teoh et al. (2024)

Figura 20 - Distribuição da contagem de objetos por imagem no conjunto sintético.




Fonte: Adaptado de Teoh et al. (2024).

4.6.4 Treinamento e Arquitetura do YOLOv8

Os autores utilizaram o YOLOv8, explorando variantes menores (n, s e m) por sua maior eficiência computacional, característica crucial em drones com hardware limitado. Os modelos foram treinados por 100 épocas com *batch sizes* de 16 e 32. A Figura 21 apresenta a relação entre número de parâmetros e FLOPs das variantes, evidenciando o aumento de custo computacional com a complexidade.

Figura 21 - Número de parâmetros (M) e FLOPs (B) das variantes do YOLOv8.



Fonte: Adaptado de Teoh et al. (2024)

4.6.5 Resultados e Avaliação Crítica

Nos experimentos conduzidos com o conjunto de imagens sintéticas, a variante YOLOv8m, com *batch size* de 32, apresentou o melhor desempenho. Este modelo alcançou mAP50 de 96,7%, mAP@[0.5,0.95] de 78,7% e F1-Score de 90,8%, operando a uma taxa de aproximadamente 67 FPS. Esses resultados demonstram elevada precisão na detecção de telhados em áreas inundadas, além de indicar a viabilidade de execução em tempo real, aspecto fundamental para aplicações práticas em contextos de emergência.


Tabela 11 - Resultados de desempenho do YOLOv8 com imagens sintéticas.

Modelo	Épocas	Batch	mAP50	mAP@[0.5,0.95]	Precisão	Recall	F1 Score	FPS
		Size						
YOLOv8n	100	16	0.965	0.769	0.953	0.862	0.905	101
YOLOv8s	100	16	0.966	0.779	0.953	0.859	0.904	95
YOLOv8m	100	16	0.966	0.787	0.952	0.865	0.906	69
YOLOv8n	100	32	0.965	0.768	0.95	0.85	0.897	97
YOLOv8s	100	32	0.965	0.779	0.954	0.859	0.904	80
YOLOv8m	100	32	0.967	0.787	0.951	0.87	0.908	67

Fonte: Teoh et al. (2024)

Quando o modelo foi aplicado em imagens reais de enchentes, observou-se uma queda significativa no desempenho. Essa diferença entre o ambiente sintético e o real pode ser atribuída a fatores como diversidade arquitetônica das edificações, presença de oclusões naturais, como árvores, maior densidade urbana que provoca sobreposição de telhados, além de variações de ângulo de voo, altitude e resolução das imagens captadas por drones. Esses elementos, ausentes ou simplificados nos dados sintéticos, ampliam o chamado *domain gap*, comprometendo a generalização do modelo.

Figura 22 - Comparação entre o ground truth e as predições das variantes YOLOv8 (n, s e m) em três cenários distintos de inundação, evidenciando o desempenho em área urbana com telhados de maior densidade e sobreposição.

Model	Scenario 1	Scenario 2	Scenario 3
Ground Truth			
YOLOv8n			
YOLOv8s			
YOLOv8m			

Fonte: Adaptado de Teoh et al. (2024)

Figura 23 - Resultados de detecção do YOLOv8 (n, s e m) comparados ao ground truth em três cenários adicionais, destacando a variação do desempenho em ambientes com diferentes padrões arquitetônicos.

Model	Scenario 1	Scenario 2	Scenario 3
Ground Truth			
YOLOv8n			
YOLOv8s			
YOLOv8m			

Fonte: Adaptado de Teoh et al. (2024)

4.6.6 Síntese Crítica

O estudo de Teoh et al. (2024) representa um avanço metodológico ao demonstrar que dados sintéticos podem reduzir a escassez de bases reais para treinamento de modelos de visão computacional aplicados à gestão de desastres naturais. A principal contribuição está na concepção de um ciclo híbrido de aprendizado, proposto no *framework* FloodIntel, em que

dados artificiais são utilizados para preparar modelos em períodos de não ocorrência de enchentes e, posteriormente, refinados com amostras reais.

Apesar dos resultados consistentes, o desafio relacionado ao *domain gap* mostra quedados artificiais ainda não substituem integralmente a complexidade das condições reais. A literatura sugere algumas estratégias para mitigar esse problema, como a diversificação dos cenários gerados (*domain randomization*), contemplando variações de iluminação, materiais, ângulos e resoluções; o uso de *fine-tuning* com amostras reais, mesmo que em número reduzido; e a adoção de técnicas de *domain adaptation*, que buscam alinhar as distribuições sintéticas e reais. Além disso, destaca-se a importância da padronização nos processos de coleta e anotação, bem como a ampliação dos conjuntos de dados para incluir diferentes classes de objetos, como escolas, hospitais e indústrias.

De forma geral, o artigo vai além do mérito técnico da integração entre Gen-AI e YOLO, apresentando também um caráter estratégico. A proposta de um ciclo contínuo de treino sintético e validação real consolida-se como uma abordagem promissora para o desenvolvimento de sistemas embarcados de monitoramento de enchentes, com potencial de aplicação em tempo real. Esse avanço contribui para reduzir lacunas críticas em situações de crise, ao mesmo tempo em que oferece bases sólidas para o desenvolvimento de novas pesquisas na área.

4.7 Análise Crítica e Síntese de Conhecimento do Artigo “Gestão de Crise Mediante a Utilização de IA” de Juan Manuel Corchado

4.7.1 Introdução e Contextualização do Estudo

Segundo Corchado (2023), a Inteligência Artificial (IA) tem ganhado destaque crescente na gestão de crises, pois oferece recursos capazes de apoiar decisões em cenários de alta complexidade. O autor, referência na área de inteligência computacional e ciência de dados, combina uma fundamentação teórica sólida com aplicações práticas, tornando sua análise especialmente relevante para pesquisas nesse campo.

O estudo ressalta o potencial da IA generativa na gestão de crises e a contextualiza dentro da evolução histórica da própria área. Ao revisitar os chamados “invernos da IA” e compará-los com o atual período de expansão, Corchado (2023) destaca tanto as oportunidades abertas pelas novas abordagens quanto os cuidados éticos e legais necessários para sua adoção.

Essa reflexão oferece um arcabouço conceitual essencial para esta pesquisa, fornecendo bases para a construção metodológica e para a análise crítica do uso da IA em contextos críticos.

4.7.2 Fundamentos e Evolução da IA: Perspectiva Histórica e Lições Aprendidas

A trajetória da Inteligência Artificial (IA) não pode ser entendida como uma linha reta de descobertas e conquistas, mas como um caminho marcado por avanços, expectativas e também momentos de retração. O marco inicial geralmente atribuído ao campo é a Conferência de Dartmouth, em 1956, quando John McCarthy cunhou o termo *Artificial Intelligence*.

Ao longo das décadas seguintes, novas subáreas foram se consolidando, como aprendizado de máquina, visão computacional, processamento de linguagem natural e redes neurais, ampliando o alcance da IA. Porém, o entusiasmo inicial foi seguido pelo chamado “inverno da IA”, vivido especialmente nas décadas de 1970 e 1980. Esse período ficou marcado pelo descompasso entre as expectativas elevadas e as limitações reais da tecnologia da época. A escassez de poder computacional, os algoritmos pouco escaláveis e a ausência de dados robustos resultaram em projetos que não conseguiram cumprir o que prometiam, levando a cortes de investimento e à desilusão de parte da comunidade científica.

Apesar disso, esse período não deve ser visto como um fracasso, mas como um ciclo de aprendizado. A experiência mostrou a importância de estabelecer metas realistas, integrar hardware, algoritmos e dados de qualidade, além de incentivar uma postura multidisciplinar. Outro ponto que emergiu com força foi a necessidade de refletir sobre os impactos éticos e sociais da IA, preocupação que se mantém central até os dias de hoje.

A partir dessas lições, o século XXI assistiu a um renascimento da IA, impulsionado pelo avanço do *deep learning* e das redes neurais convolucionais (CNNs). O que vemos hoje com a IA generativa não é um fenômeno isolado, mas fruto desse amadurecimento histórico, que alia avanços técnicos a uma consciência maior sobre responsabilidade, ética e aplicabilidade prática.

4.7.3 IA Generativa e Grandes Modelos de Linguagem (LLMs): Definições e Capacidades Estratégicas

A inteligência artificial generativa tem se consolidado como uma das principais inovações da área, representando uma etapa significativa no avanço da IA. Mais do que otimizar processos existentes, essa tecnologia amplia o horizonte de aplicações, permitindo explorar

cenários antes considerados inviáveis. Sua relevância em contextos de crise decorre da capacidade de processar grandes volumes de dados não estruturados, geralmente abundantes, fragmentados e de difícil interpretação. Diferentemente dos métodos tradicionais, a IA generativa reconhece padrões, sugere soluções e projeta tendências com elevado nível de precisão, o que pode favorecer a tomada de decisão em situações críticas.

Nesse cenário, os Grandes Modelos de Linguagem (LLMs) destacam-se como a espinha dorsal das aplicações em IA generativa. Treinados em extensos conjuntos de dados, baseiam-se em arquiteturas de transformadores e na elevada quantidade de parâmetros, como os 175 bilhões do GPT-3, o que lhes confere robustez para compreender e produzir linguagem natural em níveis sofisticados. O avanço rumo à multimodalidade — integrando texto, imagens e sinais de áudio — amplia ainda mais o potencial de uso. A possibilidade de especialização por meio de técnicas de *fine-tuning* torna esses modelos adaptáveis a domínios específicos, aumentando sua eficácia em tarefas complexas, como análise ambiental e suporte à gestão de riscos.

Contudo, a questão central reside em avaliar se a IA generativa já constitui uma resposta efetiva para a prevenção de desastres. Estudos recentes, como o de Corchado (2023), apontam que, embora o potencial seja promissor, há limitações práticas relacionadas à confiabilidade, à interpretabilidade e à integração dessas soluções em políticas públicas. Já o trabalho de Teoh et al. (2024) evidencia que aplicações em cenários de inundação, baseadas em dados sintéticos e modelos generativos, ainda se concentram no contexto pós-desastre, voltadas à resposta e ao resgate. Assim, pode-se afirmar que a IA generativa, no estágio atual, contribui mais para resposta e mitigação do que para prevenção direta, embora represente um caminho estratégico para o fortalecimento de sistemas preditivos no futuro próximo.

4.7.4 O Potencial da IA Generativa na Gestão de Crises: Uma Análise Multissetorial

O artigo analisa a inteligência artificial generativa como uma “alternativa quase perfeita” para a gestão de crises, ressaltando sua capacidade de processar e sintetizar grandes volumes de dados com rapidez e precisão. Mais do que um recurso tecnológico, a IA generativa é apresentada como um instrumento estratégico, capaz de organizar informações fragmentadas e caóticas para apoiar a tomada de decisão. Entre os exemplos de aplicação destacados pelo autor estão: simulação e modelagem de crises, análise preditiva em emergências, gestão de segurança e vigilância, operações militares, resposta a catástrofes, comunicação em crises e reconstrução pós-crise.

O diferencial da IA generativa, segundo o autor, não se limita à automação de tarefas, mas à sua função de síntese e integração. Em cenários de desastre, dados de múltiplas fontes — sensores, imagens de satélite, relatórios em tempo real e registros históricos — podem ser harmonizados para construir uma visão unificada da situação. Nesse contexto, levanta-se a possibilidade de geração de imagens sintéticas de eventos climáticos com presença de vítimas, em linha com propostas como o *ATR HarmoniSAR* (Mahmud; Kim, 2024). Entretanto, essa perspectiva deve ser analisada de forma crítica: embora útil para suprir a escassez de dados reais e treinar modelos de reconhecimento, a produção de imagens envolvendo vítimas suscita desafios éticos e riscos de vieses na representação.

No que se refere ao uso preditivo ou preventivo, a IA generativa apresenta potencial, sobretudo quando aplicada à simulação de cenários e à análise preditiva em emergências. Essas aplicações permitem antecipar impactos e otimizar a alocação de recursos, favorecendo estratégias de mitigação. Contudo, como destacam Corchado (2023) e Teoh et al. (2024), sua consolidação ainda encontra barreiras relacionadas à confiabilidade, interpretabilidade e integração em políticas públicas. Assim, no estágio atual, a IA generativa contribui mais para resposta e mitigação do que para a prevenção direta de catástrofes, ainda que represente um caminho estratégico para o fortalecimento de sistemas preditivos no futuro. Corchado caracteriza a IA generativa como uma tecnologia de ruptura, capaz de lidar com cenários caóticos e complexos típicos de situações de crise. Ao mesmo tempo, ressalta que a viabilidade e a aceitação dessa tecnologia dependem diretamente de sua utilização responsável. Princípios como transparência, responsabilidade e prestação de contas são apontados como fundamentais, e o arcabouço ético e legal aparece como condição indispensável para sua adoção em contextos críticos.

Em síntese, o artigo oferece um referencial consistente tanto do ponto de vista técnico quanto ético, servindo como base para a fundamentação metodológica desta pesquisa.

4.7.5 Análise Crítica e Síntese Metodológica

A análise integrada dos quatro estudos técnicos — *ATR HarmoniSAR* (Mahmud; Kim, 2024), *FloodNet* (Rahnemoonfar et al., 2021), *GeoDisasterAINet* (Raju et al., 2025) e Teoh et al. (2024) — em conjunto com a reflexão conceitual de Corchado (Corchado, 2023), permite delinear o estágio atual de maturidade da Inteligência Artificial aplicada à gestão de crises.

Cada uma dessas contribuições ataca desafios distintos, que vão desde a criação de bases de dados até a necessidade de interpretabilidade dos modelos em cenários críticos. O *ATR*

HarmoniSAR destaca-se pela inovação na geração de dados sintéticos para treinar detectores em missões de resgate, preenchendo lacunas de informação em situações reais. O *FloodNet* estabelece um marco na disponibilização de imagens aéreas de alta resolução acompanhadas de anotações detalhadas, fornecendo insumos robustos para tarefas de classificação, segmentação e *Visual Question Answering* (VQA). O *GeoDisasterAINet*, por sua vez, propõe um *framework* híbrido que combina CNNs, XGBoost e SVM multiclasse, associado a técnicas de interpretabilidade como o LIME, permitindo explicar classificações em contextos de alto risco. . Complementarmente, Teoh et al. (2024) demonstram o uso de modelos generativos (GANs) para criar imagens sintéticas de enchentes, ampliando a capacidade de treinamento de sistemas de detecção.

O trabalho de Corchado (Corchado, 2023) oferece a moldura conceitual para conectar essas inovações, ressaltando que o avanço atual da IA só foi possível após sucessivos ciclos de aprendizado e que sua consolidação em cenários de crise depende de fundamentos éticos sólidos, como transparência, responsabilidade e prestação de contas.

No Brasil, tais metodologias encontram campo fértil de aplicação em diferentes contextos. Em Recife (PE), cidade historicamente afetada por enchentes recorrentes, adaptações do *FloodNet* poderiam viabilizar o mapeamento urbano em tempo quase real, permitindo a identificação de áreas críticas e fornecendo subsídios para evacuações preventivas. Já no Rio de Janeiro (RJ), onde a principal vulnerabilidade está nos deslizamentos de encostas, o *GeoDisasterAINet* seria particularmente relevante, pois alia classificação de eventos com interpretabilidade, o que possibilita à Defesa Civil compreender não apenas o resultado do modelo, mas também os fatores que levaram àquela decisão. Nesse caso, dados hidrometeorológicos e geotécnicos locais poderiam ser integrados para ampliar a precisão das análises.

O Vale do São Francisco (BA/PE), marcado por secas prolongadas, constitui um cenário propício ao uso de modelos preditivos baseados em séries temporais e dados hidrometeorológicos, apoiando tanto a gestão de recursos hídricos quanto políticas de mitigação da escassez.

Em Ouro Preto (MG), os riscos são mais complexos, pois riscos geológicos e estruturais coexistem com a necessidade de preservação do patrimônio histórico. Por isso, a proposta de integrar diferentes metodologias se justifica: o *FloodNet* poderia ser empregado no monitoramento aéreo do espaço urbano com drones; o *GeoDisasterAINet* contribuiria com a interpretabilidade dos resultados, apoiando decisões transparentes em situações de risco; o *ATR HarmoniSAR* seria útil na geração de dados sintéticos para cenários de colapso estrutural,

comuns em áreas históricas; e as técnicas de IA generativa discutidas por Teoh et al. (2024) permitiriam simulações de impacto e planejamento preventivo. Essa combinação amplia a robustez da gestão de riscos em um município cuja vulnerabilidade é agravada pela topografia acidentada e pelo patrimônio cultural sensível.

Além disso, outro contexto real de aplicação em Ouro Preto seria o monitoramento de queimadas na Reserva do Pico do Itacolomy. Modelos de visão computacional treinados com dados de satélite e sensores de campo poderiam detectar focos de incêndio de forma precoce, enquanto técnicas de IA explicável possibilitariam entender as variáveis ambientais mais associadas ao risco. Essa integração fortaleceria a capacidade de resposta e prevenção em uma área de grande importância ecológica e turística.

Em síntese, a integração dessas metodologias evidencia que o avanço da IA aplicada à gestão de desastres não depende apenas da criação de novos algoritmos, mas também da capacidade de produzir dados de qualidade, assegurar a explicabilidade dos modelos e adaptar soluções às condições locais. No contexto brasileiro, a aplicabilidade prática dessas abordagens envolve a utilização de dados provenientes de diferentes fontes, como sensores meteorológicos, estações hidrológicas, imagens de satélite, registros de defesa civil, drones e até informações coletadas em redes sociais.

Do ponto de vista técnico, esses dados podem ser tratados com métodos de aprendizado profundo para reconhecimento de padrões em imagens (como CNNs aplicadas a enchentes e deslizamentos), algoritmos supervisionados para classificação de cenários (como Random Forest e SVM), séries temporais para previsão de eventos hidrológicos e frameworks híbridos que incorporam técnicas de interpretabilidade, como o LIME e o SHAP.

Na perspectiva da prevenção, essas ferramentas permitem identificar áreas de maior vulnerabilidade, prever a evolução de fenômenos extremos (chuvas intensas, secas, deslizamentos), simular cenários de impacto e otimizar a alocação de recursos, fortalecendo estratégias de mitigação. Já no pós-desastre, possibilitam o mapeamento detalhado das áreas atingidas, a quantificação de danos, a priorização de regiões para resgate e reconstrução e a análise crítica das respostas anteriores, gerando insumos para a formulação de políticas públicas mais eficazes.

Assim, essa perspectiva fundamenta a metodologia desta pesquisa em um arcabouço que une inovação tecnológica, aplicabilidade prática e responsabilidade ética, direcionado às demandas específicas de contextos brasileiros de alto risco.

4.7.6 Proposta de Aplicação Local: Previsão de Incêndios no Pico do Itacolomi (Ouro Preto/MG)

Embora este trabalho tenha como foco principal a análise e sistematização de técnicas de Inteligência Artificial aplicadas à prevenção e mitigação de desastres naturais, considera-se relevante propor um exemplo de aplicabilidade local que ilustre o potencial de integração dessas metodologias em um contexto real. Essa proposta, ainda não implementada, é voltada ao município de Ouro Preto/MG, região reconhecida tanto por sua relevância cultural quanto pela vulnerabilidade a riscos ambientais.

O *Parque Estadual do Itacolomi*, situado em Ouro Preto, constitui um espaço de elevada importância ambiental e patrimonial. Sua cobertura vegetal, formada por campos rupestres e fragmentos florestais, apresenta alta suscetibilidade a incêndios durante o período seco. Esses eventos afetam diretamente a biodiversidade, aumentam a instabilidade geotécnica das encostas e geram riscos indiretos ao patrimônio histórico edificado da cidade.

Nesse sentido, propõe-se a adaptação de metodologias já consolidadas, como o modelo *FISC-Cerrado*, originalmente aplicado na Serra do Rola Moça, para a construção de um sistema de previsão e monitoramento de incêndios no Pico do Itacolomi.

Tecnicamente, essa adaptação requer a integração de múltiplas fontes de dados: imagens de satélite (MODIS, Sentinel-2), ortofotos de VANTs com alta resolução espacial, dados meteorológicos quase em tempo real (NOAA/NCEP) e registros históricos de ocorrências fornecidos pela Defesa Civil. Esses insumos alimentariam um pipeline de Inteligência Artificial composto por: (i) Redes Neurais Convolucionais (CNNs) para detecção e segmentação de focos de incêndio; (ii) algoritmos supervisionados como Random Forest, SVM e XGBoost para classificação de áreas críticas; (iii) métodos não supervisionados, como HDBSCAN e k-means, para identificar padrões emergentes de propagação; e (iv) técnicas de IA explicável (XAI), como LIME e SHAP, garantindo transparência na interpretação das previsões.

Apesar dos desafios técnicos — como a escassez de séries históricas locais, a heterogeneidade da vegetação do Itacolomi e a necessidade de infraestrutura computacional robusta para processamentos em tempo quase real — os benefícios esperados são significativos. Entre eles, destacam-se a antecipação tática de rotas de propagação, a otimização do posicionamento de brigadas de combate, o planejamento de aceiros preventivos e a proteção integrada do patrimônio natural e cultural.

A viabilidade dessa proposta também depende de um arranjo colaborativo entre instituições locais e regionais. O Instituto Federal de Minas Gerais (IFMG) e a Universidade

Federal de Ouro Preto (UFOP) podem contribuir com expertise acadêmica, desenvolvimento de algoritmos e formação de recursos humanos. Já a Defesa Civil Municipal e o Instituto Estadual de Florestas (IEF) desempenham papéis fundamentais na disponibilização de dados de campo e na implementação operacional. Essa cooperação entre ciência, órgãos públicos e sociedade civil fortalece a sustentabilidade institucional do sistema e amplia suas chances de sucesso prático.

É importante ressaltar que esta proposta não foi implementada no presente estudo, configurando-se como possibilidade para pesquisas futuras. Sua inclusão reforça a conexão entre a fundamentação teórica apresentada e as demandas práticas de municípios vulneráveis, além de alinhar-se diretamente às diretrizes globais de sustentabilidade, em especial os Objetivos de Desenvolvimento Sustentável (ODS) 11, 13 e 15, que tratam respectivamente da resiliência urbana, da ação climática e da preservação da vida terrestre. Dessa forma, o trabalho não apenas consolida bases conceituais e técnicas, mas também aponta caminhos de aplicação concreta que podem orientar avanços futuros no campo da Inteligência Artificial aplicada à gestão de riscos.

5 RESULTADOS

5.1 Análise Crítica e Síntese de Desempenho dos Modelos

Esta seção consolida e aprofunda a análise das metodologias de ponta discutidas na revisão da literatura, indo além da descrição individual dos trabalhos. O objetivo é fornecer uma avaliação técnica e comparativa que sirva de base para as aplicações propostas, destacando como os avanços em Inteligência Artificial têm enfrentado e superado desafios históricos da gestão de crises.

5.1.1 GeoDisasterAINet (Raju *et al.*, 2025): Interpretabilidade e Robustez

O GeoDisasterAINet (Raju *et al.*, 2025) constitui um marco metodológico por integrar múltiplas técnicas de aprendizado em cascata. A arquitetura combina conjuntos de modelos de redes neurais convolucionais (CNNs), responsáveis pela extração de padrões visuais, com o refinamento do algoritmo XGBoost e a capacidade discriminativa de uma Máquina de Vetor de Suporte (SVM) multiclasse. Essa abordagem híbrida buscou superar limitações dos métodos convencionais e obteve 96,37% de acurácia no conjunto de teste, conforme validado pela matriz de confusão e pelas curvas ROC. Os valores de AUC oscilaram entre 0,91 para enchentes e 0,97 para ciclones e incêndios florestais, indicando não apenas acertos consistentes, mas também elevada confiança do modelo nas classificações.

A grande inovação, contudo, reside na integração com o LIME (Local Interpretable Model-Agnostic Explanations). Em cenários de crise, a interpretabilidade é tão importante quanto a acurácia. O LIME fornece explicações visuais ao destacar as regiões da imagem que contribuíram para a decisão algorítmica, como a presença de nuvens em espiral em ciclones ou a saturação do solo em áreas alagadas. Essa capacidade de justificar recomendações transforma o sistema em um aliado confiável da Defesa Civil, garantindo que os gestores compreendam e validem as decisões antes de agir.

5.1.2 FloodNet (Rahnemoonfar *et al.*, 2021): O Paradigma do Dataset de Alta Resolução

Diferentemente de novas arquiteturas, o FloodNet representa uma contribuição de infraestrutura essencial: a criação do primeiro dataset público de imagens aéreas de alta resolução para gestão de desastres. Capturadas por drones, as imagens possuem resolução

aproximada de 1,5 cm/pixel, permitindo análises em nível de pixel, como identificação de estradas, veículos e edifícios afetados. O dataset inclui anotações para classificação, segmentação semântica e Visual Question Answering (VQA), o que possibilitou que modelos como o InceptionNetV3 alcançassem 95,09% de acurácia em classificação e o PSPNet atingisse um mIoU de 80,35% na segmentação.

Apesar da relevância, algumas limitações foram evidenciadas. O desequilíbrio de classes, como a baixa frequência da categoria *pool*, comprometeu resultados, assim como a detecção de objetos pequenos (*vehicle*, *road-flooded*). Além disso, o VQA teve desempenho insatisfatório em questões de contagem, raramente superando 35% de acurácia, revelando que os modelos ainda enfrentam dificuldades em migrar da percepção (identificar um carro) para a cognição (contar quantos carros estão presentes). O FloodNet, ao mesmo tempo que expôs essas limitações, ofereceu a base necessária para que pesquisas futuras avancem rumo a uma IA capaz de apoiar a resposta de emergência em tarefas mais complexas.

5.1.3 ATR HarmoniSAR e IA Generativa (Mahmud *et al.*, 2024; Teoh *et al.*, 2024): A Revolução dos Dados Sintéticos

A escassez de dados reais em cenários de desastre constitui um dos maiores obstáculos éticos e técnicos da área. Nesse contexto, a IA generativa desponta como alternativa promissora. O estudo do ATR HarmoniSAR aplicou a técnica de *Poisson Image Editing* para inserir vítimas sintéticas em cenários de desastre, ajustando cor, textura e iluminação para gerar imagens praticamente indistinguíveis das reais.

O impacto dessa abordagem é evidente: o YOLOv5x teve sua precisão média (AP50) elevada de 29,3% para 92,4% após o treinamento com o ATR 1k Victim Dataset. Outras arquiteturas, como Faster R-CNN e SSD MobileNetV2, também apresentaram ganhos significativos. Complementarmente, Teoh *et al.* (2024) demonstraram o potencial das GANs (*Generative Adversarial Networks*) para criar imagens sintéticas de enchentes, reforçando a viabilidade do uso de dados artificiais em situações raras ou pouco documentadas.

Ao permitir que pesquisadores gerem dados realistas em larga escala, a IA generativa inaugura um novo paradigma: a transição da gestão reativa, baseada na coleta pós-desastre, para a gestão proativa, sustentada por simulações robustas e diversificadas.

Tabela 12 - Resumo comparativo das metodologias de IA para gestão de desastres.

Estudo	Técnica Central	Problema Abordado	Principal Resultado	Limitações
GeoDisasterAINet	Ensemble Learning (CNNs, XGBoost, SVM) + LIME	Classificação de desastres e falta de transparência	96,37% de acurácia; interpretabilidade via LIME	Desempenho reduzido em classes de difícil distinção
FloodNet	Dataset aéreo de alta resolução	Baixa qualidade de imagens de satélite/redes sociais	Base pública multitarefa; mIoU 80,35% na segmentação	Desequilíbrio de classes; baixa performance em objetos pequenos
ATR HarmoniSAR	IA Generativa + Poisson Image Editing	Escassez de dados reais para detecção de vítimas	Acurácia do YOLOv5x saltou de 29,3% para 92,4%	Exigência de alto poder computacional
Teoh et al.	GANs	Escassez de amostras reais em enchentes	Criação de imagens sintéticas para fortalecimento do treinamento	Limitações na diversidade/qualidade dos dados gerados

Fonte: Adaptado de Mahmud et al. (2024), Rahnemoonfar et al. (2021), Raju et al. (2025), Teoh et al. (2024).

6 CONSIDERAÇÕES FINAIS

A presente pesquisa evidenciou que a Inteligência Artificial constitui um recurso estratégico na prevenção e mitigação de desastres naturais, com potencial de transformar dados complexos em informações acionáveis para a tomada de decisão. Foram discutidos diferentes modelos e metodologias, incluindo redes neurais convolucionais, técnicas de interpretabilidade, uso de dados sintéticos e integração de sensoriamento remoto, que, quando aplicados de forma consistente, oferecem precisão elevada e capacidade de resposta em cenários críticos.

Como desdobramento prático, destaca-se a possibilidade de aplicação dessas metodologias em contextos específicos de alta vulnerabilidade, como áreas de preservação ambiental que enfrentam pressões antrópicas e riscos recorrentes. Nesse sentido, a cidade de Ouro Preto (MG) apresenta-se como um caso emblemático, não apenas pelo seu patrimônio histórico e cultural, mas também por abrigar ecossistemas frágeis em sua zona de entorno. O Parque Estadual do Itacolomi, em especial, reúne características que justificam sua escolha como área piloto: vegetação altamente suscetível a incêndios durante o período seco, topografia acidentada que favorece a propagação do fogo e proximidade com áreas urbanizadas, ampliando os riscos socioambientais.

A experiência adquirida em outros biomas, como no Cerrado, demonstrou que sistemas baseados em IA podem prever a propagação de incêndios em tempo quase real, integrando dados ambientais, climáticos e topográficos (OLIVEIRA *et al.*, 2023). A adaptação desse tipo de abordagem para o contexto de Ouro Preto exigiria a coleta e integração de dados locais, contemplando desde registros históricos de queimadas até variáveis meteorológicas de alta resolução. Apesar dos desafios relacionados à escassez de dados rotulados, à sazonalidade marcante e à necessidade de infraestrutura computacional robusta, os benefícios esperados são expressivos, abrangendo desde a antecipação de rotas de propagação até a preservação do patrimônio natural e cultural.

Adicionalmente, ressalta-se que a proposta aqui apresentada pode ser expandida para outras áreas de preservação ambiental em Minas Gerais e no Brasil, onde a pressão por urbanização, turismo ou atividades econômicas intensifica a ocorrência de incêndios e outros desastres ambientais. O Itacolomi, nesse contexto, pode funcionar como caso inicial de adaptação e validação metodológica, servindo de modelo replicável para outros territórios vulneráveis.

A proposta também dialoga diretamente com os Objetivos de Desenvolvimento Sustentável da Agenda 2030, em especial o ODS 11, que busca tornar as cidades mais seguras, resilientes e sustentáveis, e o ODS 13, voltado à ação contra a mudança global do clima. A implementação de sistemas inteligentes de prevenção e monitoramento fortalece não apenas a resiliência urbana, mas também a governança ambiental em escala local e regional.

Portanto, este trabalho não se encerra em sua análise comparativa das metodologias de IA, mas abre caminho para novas pesquisas que adaptem, testem e validem soluções em áreas de preservação ambiental. Recomenda-se que investigações futuras priorizem a aplicação prática dessas ferramentas em Ouro Preto, com foco inicial no Pico do Itacolomi, e que, em seguida, ampliem seu escopo para outros territórios, integrando academia, gestores públicos e sociedade civil em uma agenda de inovação tecnológica voltada à redução de riscos e à proteção socioambiental. Dessa forma, o potencial da Inteligência Artificial poderá ser convertido em soluções tangíveis que reforcem a resiliência local, ampliem a capacidade de resposta a emergências e contribuam para um futuro mais seguro e sustentável.

REFERÊNCIAS

- AHMAD, T. et al. Artificial intelligence in disaster management: applications, challenges, and future directions. *International Journal of Disaster Risk Reduction*, Amsterdam, v. 97, p. 103–120, out. 2023.
- ARTAXO, P.; RIZZO, L. V.; MACHADO, C. Artificial intelligence and climate change: new tools for resilience. *Climate Research*, Amersham, v. 78, n. 2, p. 145–160, 2024.
- BALL, J. et al. Machine learning for wildfire prediction and risk assessment: a review. *Ecological Modelling*, Amsterdam, v. 464, p. 109–122, 2022.
- BISHOP, C. M. *Pattern recognition and machine learning*. New York: Springer, 2006.
- BRASIL. Instrução Normativa nº 1, de 24 de agosto de 2012. Aprova a Classificação e Codificação Brasileira de Desastres – COBRADE. Brasília: Ministério da Integração Nacional, 2012.
- BRASIL; ORGANIZAÇÃO DAS NAÇÕES UNIDAS (ONU). *Objetivos de Desenvolvimento Sustentável*. Brasília: Ipea. [s. d.]. Disponível em: <https://www.ipea.gov.br/ods>. Acesso em: 1 set. 2025.
- CHEN, Y. et al. Earthquake early warning using deep learning: challenges and opportunities. *Seismological Research Letters*, Oakland, v. 94, n. 1, p. 45–60, jan. 2023.
- CORCHADO, J. M. *Gestión de crisis mediante la utilización de inteligencia artificial*. In: CORCHADO, J. M. (Ed.). *La Inteligencia Artificial y la Gestión de Crisis*. Madrid: Dykinson, 2023.
- DALAGNOL, R. et al. Satellite data and machine learning for landslide prediction in tropical regions. *Remote Sensing of Environment*, Amsterdam, v. 289, p. 113–143, maio 2023.
- HE, K. et al. *Deep residual learning for image recognition*. In: PROCEEDINGS OF THE IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2016, Las Vegas. Proceedings. [S. l.]: IEEE, 2016. p. 770–778.
- HUANG, G. et al. *Densely connected convolutional networks*. In: PROCEEDINGS OF THE IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2017, Honolulu. Proceedings. [S. l.]: IEEE, 2017. p. 4700–4708.
- INSTITUTO DE PESQUISA ECONÔMICA APLICADA (IPEA). *ODS 11 no Brasil: cidades e comunidades sustentáveis*. Brasília: Ipea, 2024.
- INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). *Climate change 2014: synthesis report*. Geneva: IPCC, 2014.
- INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). *Climate change 2022: impacts, adaptation and vulnerability*. Geneva: IPCC, 2022.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). *Climate change 2023: synthesis report*. Geneva: IPCC, 2023.

KONDO, S. et al. Ethical implications of AI in disaster risk reduction. *AI & Society*, Berlin, v. 36, n. 4, p. 1001–1014, dez. 2021.

LAM, R. et al. Advances in AI-based tropical cyclone prediction: the GraphCast and Pangu-Weather models. *Nature Reviews Earth & Environment*, London, v. 4, p. 155–168, mar. 2023.

LI, Y. et al. Disaster response with AI-enabled drones and robotics. *Remote Sensing*, Basel, v. 12, n. 21, p. 3542, nov. 2020.

LIU, H. et al. Challenges and opportunities of AI for disaster management. *Natural Hazards*, Dordrecht, v. 111, n. 1, p. 57–80, 2022.

LUO, X. et al. Applications of convolutional neural networks for disaster image classification. *IEEE Access*, New York, v. 10, p. 34567–34578, 2022.

MAHMUD, F.; KIM, S. ATR HarmoniSAR: a system for enhancing victim detection in robot-assisted disaster scenarios. *Engineering Applications of Artificial Intelligence*, Amsterdam, v. 128, p. 187460, fev. 2024.

MENESES, P. R.; ALMEIDA, T. *Geotecnologias e processamento digital de imagens: fundamentos e aplicações*. Brasília: UnB, 2012.

RAHNEMOONFAR, M. et al. FloodNet: a high-resolution aerial imagery dataset for postflood scene understanding. *IEEE Transactions on Geoscience and Remote Sensing*, New York, v. 59, n. 11, p. 8964–8977, nov. 2021.

RAJU, G. P. et al. GeoDisasterAINet: an explainable deep ensemble framework for disaster classification. *Applied Intelligence*, Norwell, 2025.

REDMON, J. et al. *You Only Look Once: Unified, Real-Time Object Detection*. In: PROCEEDINGS OF THE IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2016, Las Vegas. Proceedings. [S. l.]: IEEE, 2016. p. 779–788.

RUSSELL, S.; NORVIG, P. *Artificial intelligence: a modern approach*. 3. ed. Upper Saddle River: Prentice Hall, 2013.

SANTA CATARINA. Defesa Civil. *Plano Estadual de Proteção e Defesa Civil*. Florianópolis: Governo de Santa Catarina, 2017.

SHUKLA, A. et al. IoT-based disaster prediction systems: a review. *IEEE Internet of Things Journal*, New York, v. 8, n. 10, p. 1234–1246, maio 2021.

SIDI. *Neural networks informadas por física e modelos de linguagem em IA aplicada a desastres*. 2024. Disponível em: <https://sidi.org.br>. Acesso em: 1 set. 2025.

SINGH, R. et al. GeoDisasterAINet: deep learning-based framework for disaster detection. *International Journal of Disaster Risk Reduction*, Amsterdam, v. 92, p. 102–115, ago. 2023.

TAN, M.; LE, Q. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. In: PROCEEDINGS OF THE INTERNATIONAL CONFERENCE ON MACHINE LEARNING, 2019, Long Beach. Proceedings... [S. l.]: PMLR, 2019. p. 6105–6114.

TEOH, S. et al. Flood detection using generative AI and remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, Amsterdam, v. 130, p. 103225, set. 2025.

TEOH, S. et al. Synthetic flood image generation using generative adversarial networks. *Remote Sensing Letters*, Abingdon, v. 15, n. 2, p. 135–144, 2024.

UNITED NATIONS (ONU). *Sustainable Development Report 2023*. New York: UN, 2023.

UNDRR. Global Platform for Disaster Risk Reduction. Proceedings. Geneva: United Nations Office for Disaster Risk Reduction, 2017.

VOOSEN, P. Google's flood forecasting project expands. *Science*, Washington, v. 382, n. 6667, p. 113–115, out. 2023.

YIN, Z. et al. Integrating AI into decision support systems for disaster management. *Decision Support Systems*, Amsterdam, v. 149, p. 113–122, out. 2021.

ZHANG, J. et al. Remote sensing and AI for rapid disaster assessment. *International Journal of Remote Sensing*, Abingdon, v. 41, n. 24, p. 9192–9210, 2020.