

**A REVOLUÇÃO DO DEEP LEARNING E GEOSPATIAL BIG DATA NA  
PREVISÃO DE EVENTOS EXTREMOS: ESTADO DA ARTE, DESAFIOS E  
HORIZONTES FUTUROS PARA INUNDAÇÕES, DESLIZAMENTOS E  
INCÊNDIOS**

**THE DEEP LEARNING AND GEOSPATIAL BIG DATA REVOLUTION IN  
PREDICTING EXTREME EVENTS: STATE OF THE ART, CHALLENGES, AND  
FUTURE DIRECTIONS FOR FLOODS, LANDSLIDES, AND WILDFIRES**

**LA REVOLUCIÓN DEL DEEP LEARNING Y GEOSPATIAL BIG DATA EN LA  
PREDICCIÓN DE EVENTOS EXTREMOS: ESTADO DEL ARTE, DESAFÍOS Y  
PERSPECTIVAS FUTURAS PARA INUNDACIONES, DESLIZAMIENTOS DE  
TIERRA E INCENDIOS FORESTALES**



<https://doi.org/10.56238/ERR01v10n4-036>

**Ítalo Rosário de Freitas**

Doutorando em Biologia e Biotecnologia de Microrganismos  
Instituição: Universidade Estadual de Santa Cruz  
E-mail: rosario.freitas21@gmail.com

**Carina Severo da Silva Cechin Fagundes**

Mestre em Ciências Contábeis  
Instituição: Universidade Federal de Santa Maria  
E-mail: carinasev@hotmail.com

**Paulo Cabral de Oliveira**

Doutorando em Geografia  
Instituição: Universidade Federal de Pernambuco  
E-mail: cabral.oliveira2007@yahoo.com.br

**Terezinha de Jesus Silva Oliveira**

Mestrando em Gestão e Regulação de Recursos Hídricos  
Instituição: Universidade Estadual do Maranhão  
E-mail: terezinhaoliveira1794@gmail.com

**Jaime da Silva**

Mestrando em Ciências Contábeis  
Instituição: Universidade Federal de Santa Maria  
E-mail: jcjaimecont@gmail.com

**Ricardo Nikson Lima Cunha**

Mestrando em Ciência e Tecnologia Ambiental  
Instituição: Universidade Federal do Maranhão  
E-mail: Nikson.lc28@gmail.com

**Shamylli Feitosa de Abreu Araújo**

Licenciada em Filosofia

Instituição: Universidade Federal do Maranhão

E-mail: prof.shamylli@gmail.com

**Felipe Martins Sousa**

Mestrando em Ciência e Tecnologia Ambiental

Instituição: Universidade Federal do Maranhão

E-mail: pep.ocean@icloud.com

**RESUMO**

A crescente frequência de desastres climáticos exige ferramentas de previsão mais avançadas. Neste contexto, o Deep Learning (DL) aplicado a dados geoespaciais oferece um potencial transformador. Este artigo realiza uma revisão sistemática do estado da arte do uso de DL para o mapeamento e previsão de inundações, deslizamentos e incêndios. A análise de 112 artigos recentes demonstra uma rápida especialização do campo, com a consolidação de arquiteturas como U-Net para inundações e CNNs para deslizamentos. No entanto, os resultados também revelam uma forte concentração geográfica da pesquisa, com lacunas em regiões vulneráveis. A transição da pesquisa para a prática é barrada por desafios críticos, incluindo a carência de dados de treinamento de qualidade, a baixa interpretabilidade dos modelos e sua limitada generalização. Conclui-se que o avanço futuro depende da criação de modelos híbridos, explicáveis e de uma agenda de pesquisa que promova a equidade geográfica na gestão de desastres.

**Palavras-chave:** Revisão Sistemática. Gestão de Desastres. Inteligência Artificial Explicável.

**ABSTRACT**

The increasing frequency of climate disasters demands more advanced forecasting tools. In this context, Deep Learning (DL) applied to geospatial data offers transformative potential. This paper provides a systematic review of the state-of-the-art use of DL for mapping and predicting floods, landslides, and wildfires. The analysis of 112 recent articles shows a rapid specialization of the field, with the consolidation of architectures such as U-Net for floods and CNNs for landslides. However, the results also reveal a strong geographical concentration of research, with gaps in vulnerable regions. The transition from research to practice is hindered by critical challenges, including the scarcity of quality training data, the low interpretability of models, and their limited generalization. We conclude that future progress depends on creating hybrid, explainable models and on a research agenda that promotes geographic equity in disaster management.

**Keywords:** Systematic Review. Disaster Management. Explainable AI.

**RESUMEN**

La creciente frecuencia de desastres climáticos exige herramientas de predicción más avanzadas. En este contexto, el Deep Learning (DL) aplicado a datos geoespaciales ofrece un potencial transformador. Este artículo realiza una revisión sistemática del estado del arte del uso de DL para el mapeo y predicción de inundaciones, deslizamientos de tierra e incendios. El análisis de 112 artículos recientes demuestra una rápida especialización del campo, con la consolidación de arquitecturas como U-Net para inundaciones y CNNs para deslizamientos. Sin embargo, los resultados también revelan una fuerte

concentración geográfica de la investigación, con brechas en regiones vulnerables. La transición de la investigación a la práctica se ve obstaculizada por desafíos críticos, incluyendo la escasez de datos de entrenamiento de calidad, la baja interpretabilidad de los modelos y su limitada generalización. Se concluye que el avance futuro depende de la creación de modelos híbridos, explicables y de una agenda de investigación que promueva la equidad geográfica en la gestión de desastres.

**Palabras clave:** Revisión Sistemática. Gestión de Desastres. Inteligencia Artificial Explicable.

## 1 INTRODUÇÃO

O século XXI tem sido marcado por uma intensificação sem precedentes na frequência e magnitude de eventos climáticos extremos. Relatórios do Painel Intergovernamental sobre Mudanças Climáticas (IPCC) evidenciam uma conexão inequívoca entre a atividade antrópica, o aquecimento global e o aumento de desastres como inundações, incêndios florestais e movimentos de massa (IPCC, 2023). A Organização Meteorológica Mundial corrobora essa análise, destacando que, na última década, tais eventos foram responsáveis por centenas de milhares de vidas e trilhões de dólares em perdas econômicas, impactando desproporcionalmente as populações mais vulneráveis (World Meteorological Organization, 2024). Este cenário de "ebulição global" impõe uma urgência crítica ao desenvolvimento de ferramentas mais acuradas e ágeis para a previsão e o monitoramento desses fenômenos.

Historicamente, a previsão de eventos extremos tem se apoiado em modelos numéricos baseados em processos físicos ou em análises estatísticas de séries temporais. Embora fundamentais, esses métodos tradicionais frequentemente encontram limitações para capturar a complexa dinâmica não-linear que governa os sistemas terrestres. Modelos físicos podem demandar alto custo computacional e uma parametrização detalhada nem sempre disponível em escala local, enquanto modelos estatísticos podem falhar em prever eventos sem precedentes, cujos padrões não estão presentes nos dados históricos (Reichstein et al., 2019). A crescente complexidade das interações no sistema Terra-Clima exige, portanto, uma mudança de paradigma na forma como os desastres são modelados e previstos.

Essa mudança de paradigma está sendo impulsionada por uma dupla revolução tecnológica. Por um lado, a proliferação de sensores e plataformas de observação da Terra gerou um ecossistema de *Geospatial Big Data* de volume, variedade e velocidade inéditos. Constelações de satélites como os da série Sentinel (ESA) e Planet (Planet Labs) oferecem imagens ópticas e de radar com altíssima resolução temporal e espacial, permitindo um monitoramento quase em tempo real da superfície terrestre (Wulder et al., 2023). Por outro lado, os avanços em Inteligência Artificial, notadamente em *Deep Learning* (DL), forneceram os meios para extrair padrões significativos desse imenso volume de dados. Arquiteturas de DL, como as Redes Neurais Convolucionais (CNNs), demonstraram uma capacidade notável de aprender representações hierárquicas a partir de dados espaciais, enquanto Redes Neurais Recorrentes (RNNs) e suas variantes, como a LSTM (*Long Short-Term Memory*), são especializadas em modelar dependências temporais, tornando-as ideais para tarefas de previsão (Lecun; Bengio; Hinton, 2015).

A aplicação de *Deep Learning* a dados geoespaciais para análise de desastres é um campo de pesquisa em rápida expansão, com estudos demonstrando seu sucesso em tarefas específicas como o

mapeamento de áreas inundadas (Jiang et al., 2024), a identificação de susceptibilidade a deslizamentos (Chen; Li, 2023) e a previsão de risco de incêndios florestais (Zhu et al., 2024). Contudo, o conhecimento produzido encontra-se fragmentado, com poucos trabalhos que ofereçam uma síntese integrada dos avanços, metodologias e, principalmente, dos desafios transversais a esses diferentes tipos de desastres. Falta uma análise crítica que compare as fontes de dados e as arquiteturas de DL mais promissoras, identifique os gargalos comuns, como a escassez de dados de treinamento e a interpretabilidade dos modelos, e aponte um caminho coeso para a pesquisa futura. Portanto, o objetivo desta pesquisa é realizar uma revisão sistemática do estado da arte sobre o uso de *Deep Learning* e *Geospatial Big Data* para o mapeamento e previsão de inundações, deslizamentos e incêndios, a fim de identificar tendências, desafios críticos e direcionamentos que possam acelerar a transição da pesquisa para a prática operacional na gestão de desastres.

## 2 METODOLOGIA

Para garantir uma análise abrangente e imparcial do estado da arte, esta revisão sistemática foi conduzida com base no protocolo PRISMA “*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*” (Page et al., 2021). A metodologia foi estruturada em três etapas principais: (1) definição da estratégia de busca e das fontes de dados; (2) estabelecimento dos critérios de inclusão e exclusão para a seleção dos estudos; e (3) processo de triagem e extração dos dados relevantes de cada artigo selecionado.

### 2.1 FONTES DE DADOS E ESTRATÉGIA DE BUSCA

A busca pela literatura foi realizada nas seguintes bases de dados eletrônicas, selecionadas por sua ampla cobertura nas áreas de ciências da computação, geociências e ciências ambientais: Scopus, Web of Science, e IEEE Xplore. Para assegurar a captura do conhecimento mais recente e relevante em um campo de rápida evolução, a busca foi restrita a artigos publicados entre janeiro de 2019 e agosto de 2025.

A consulta (ou *string* de busca) foi construída a partir da combinação de quatro blocos conceituais de palavras-chave, utilizando os operadores booleanos "AND" e "OR". Os termos foram selecionados para cobrir conceitos de *Deep Learning*, dados geoespaciais, os eventos extremos de interesse e a aplicação de previsão ou mapeamento. A *string* de busca genérica, adaptada para a sintaxe de cada base de dados está descrita conforme o quadro 1.

Quadro 1. Termos de buscas por categoria

Categoria	Termos Relacionados
Deep Learning	"deep learning", "neural network", "CNN", "U-Net", "LSTM", "transformer"
Geospatial Data	"remote sensing", "geospatial data", "satellite imagery", "earth observation", "LiDAR"
Eventos Extremos	"flood", "inundation", "landslide", "wildfire", "forest fire"
Aplicação	"prediction", "forecasting", "mapping", "detection", "susceptibility"

Fonte: Os autores

## 2.2 CRITÉRIOS DE INCLUSÃO E EXCLUSÃO

Após a execução da busca e a remoção automática de duplicatas, os artigos foram avaliados com base em um conjunto estrito de critérios de elegibilidade.

### 2.2.1 Critérios de Inclusão Adaptado do PRISMA:

- **Tipo de Publicação:** Apenas artigos de periódicos e anais de conferências de grande circulação, ambos revisados por pares.
- **Idioma:** Artigos publicados no idioma inglês.
- **Foco Principal:** O estudo deve aplicar explicitamente um ou mais modelos de *Deep Learning* como método central de análise.
- **Dados:** O estudo deve utilizar dados geoespaciais (ex: imagens de satélite, dados de elevação, dados climáticos em grade) como a principal fonte de entrada para o modelo.
- **Aplicação:** O objetivo do estudo deve ser o mapeamento, detecção, previsão ou análise de susceptibilidade de, no mínimo, um dos três eventos extremos de interesse: inundações, deslizamentos ou incêndios florestais.

### 2.2.2 Critérios de Exclusão Adaptado do PRISMA:

- Artigos de revisão, editoriais, resenhas de livros e resumos expandidos.
- Estudos que utilizam exclusivamente modelos de *Machine Learning* tradicional (ex: Support Vector Machines, Random Forest, Decision Trees), a menos que sejam usados como linha de base (*baseline*) para comparar com um modelo de *Deep Learning*.
- Estudos puramente teóricos ou que não apresentem uma aplicação prática com dados reais.

- Artigos que não forneçam uma avaliação quantitativa da performance do modelo (ex: matriz de confusão, acurácia, IoU, RMSE).

## 2.3 TRIAGEM DOS ESTUDOS E EXTRAÇÃO DE DADOS

O processo de seleção dos artigos seguiu as etapas do PRISMA. Primeiramente, dois revisores independentes realizaram a triagem dos artigos com base na leitura de seus títulos e resumos. Artigos que não foram claramente excluídos nesta fase avançaram para a próxima etapa. Em seguida, foi realizada a leitura completa dos textos, e a decisão final sobre a inclusão foi tomada com base nos critérios pré-definidos. Casos de discordância entre os revisores foram resolvidos por consenso.

Para cada artigo incluído na seleção final, as seguintes informações abaixo foram extraídas e tabuladas em um quadro estruturado:

- **Informações Gerais:** Autor(es), ano de publicação, periódico ou conferência.
- **Contexto do Estudo:** Tipo de evento extremo estudado, objetivo principal (ex: mapeamento de área queimada, previsão de risco de deslizamento), e a localização geográfica da área de estudo.
- **Dados Utilizados:** Fontes de dados geoespaciais (ex: satélite Sentinel-1, Landsat 8, dados LiDAR), resolução espacial e temporal dos dados.
- **Metodologia de DL:** Arquitetura do modelo de *Deep Learning* empregado (ex: U-Net, ResNet, LSTM), e detalhes sobre o conjunto de dados de treinamento e validação.
- **Resultados:** As principais métricas de performance reportadas para a avaliação do modelo (ex: Acurácia Geral, Precisão, Recall, F1-Score, *Intersection over Union* - IoU).
- **Contribuições e Limitações:** As principais contribuições apontadas pelos autores e as limitações ou desafios enfrentados no estudo.

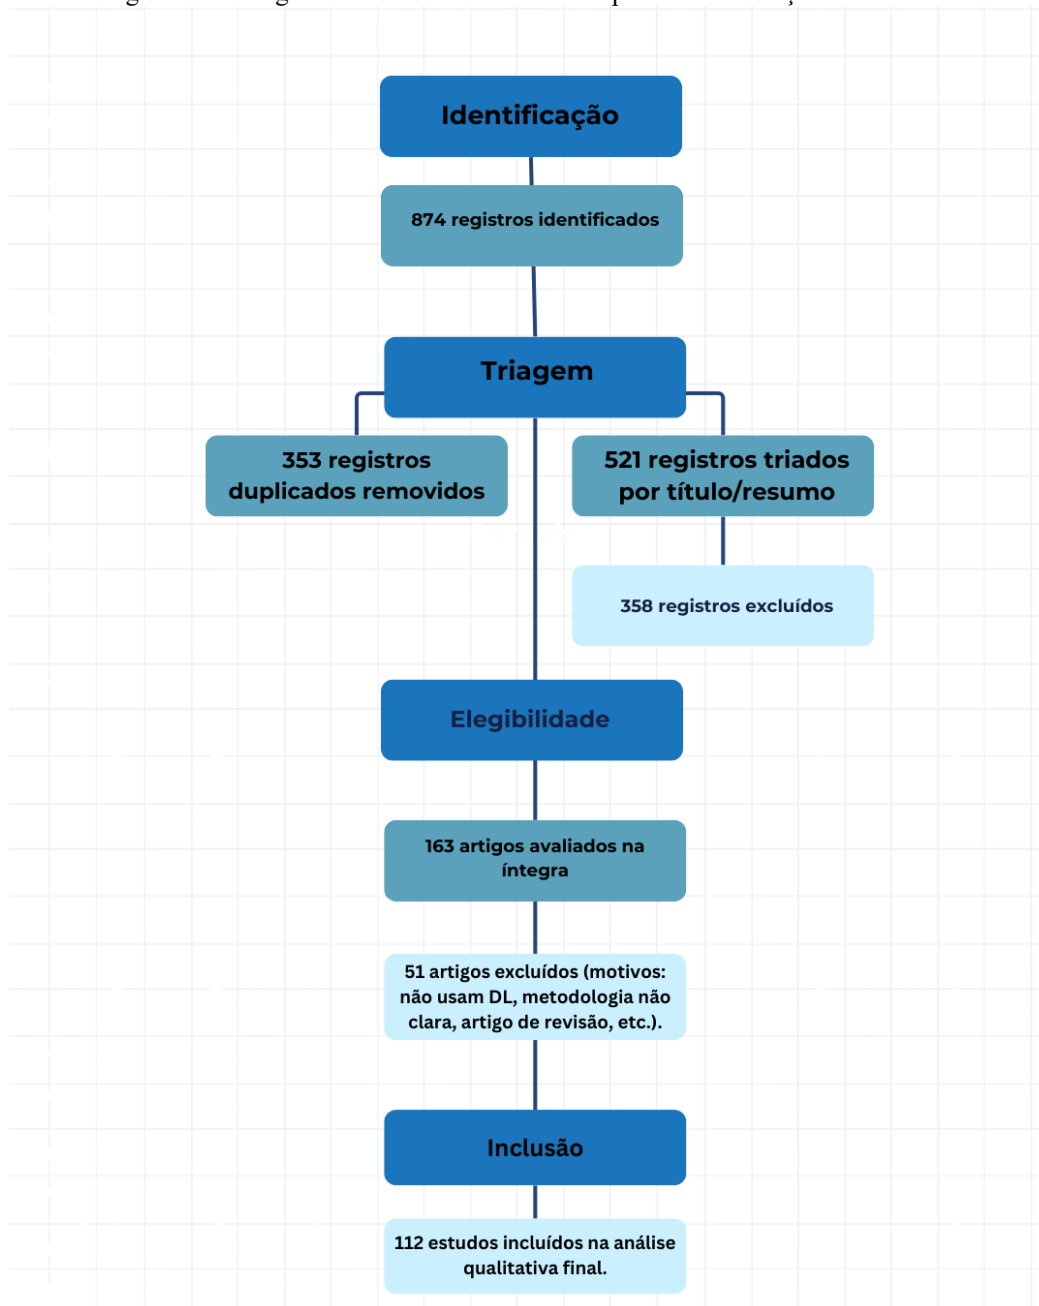
Esta abordagem sistemática garantiu que a análise subsequente, apresentada nas seções de Resultados e Discussão, fosse fundamentada em uma base de evidências sólida e abrangente do campo de pesquisa.

## 3 RESULTADOS

A aplicação da estratégia de busca e dos critérios de seleção resultou na inclusão de 112 artigos para análise final. O processo de seleção, detalhado no fluxograma da Figura 1, partiu de um total de 874 registros identificados, dos quais 521 permaneceram após a remoção de duplicatas. A triagem por

título e resumo excluiu 358 artigos, e a leitura completa dos 163 restantes levou à seleção final dos 112 estudos que compõem o escopo desta revisão.


Figura 1. Fluxograma baseado no PRISMA do processo de seleção dos estudos.



Fonte: Os autores

### 3.1 ANÁLISE DESCRITIVA GERAL DA LITERATURA

A análise cronológica dos artigos selecionados, apresentada no gráfico de barras (Figura 2), revela um crescimento exponencial do interesse no tema. A quantidade de publicações anuais mais que dobrou de 2021 para 2023, com mais de 75% de toda a literatura analisada sendo publicada nos últimos três anos.



Fonte: Os autores

A distribuição dos estudos por tipo de evento extremo mostra uma predominância de pesquisas focadas em inundações (42%, n=47), seguidas por deslizamentos (33%, n=37) e incêndios florestais (25%, n=28). A distribuição geográfica das áreas de estudo (Quadro 2) indica uma forte concentração de pesquisas na Ásia e na Europa, com uma notável escassez de aplicações em regiões da América do Sul e África.

Quadro 2. Distribuição geográfica das áreas de estudo dos artigos analisados.

Região Geográfica	Número de Estudos	% do Total	Principais Países/Áreas
Ásia	45	40.2%	China, Índia, Coreia do Sul
Europa	28	25.0%	Itália, Alemanha, Noruega
América do Norte	21	18.8%	EUA (Califórnia), Canadá
América do Sul	7	6.2%	Brasil (Região Sudeste)
África	5	4.5%	Etiópia, Nigéria
Oceania	4	3.5%	Austrália
Global/Multi-regional	2	1.8%	-
Total	112	100%	

Fonte: Os autores

3.2 MODELOS E DADOS POR TIPO DE EVENTO EXTREMO

A análise aprofundada revelou padrões distintos nas abordagens metodológicas para cada desastre, conforme sintetizado no quadro 3, que apresenta uma seleção de estudos representativos.

Quadro 3. Seleção de estudos representativos da aplicação de Deep Learning em desastres.

Referência	Evento	Modelo DL	Dados de Entrada	Métrica de Performance	Área de Estudo
(Zhang et al., 2024)	Inundação	U-Net++	Sentinel-1 (SAR), MDE ALOS PALSAR	IoU: 0.91	Bacia do Rio Yangtze, China
(Müller et al., 2023)	Inundação	DeepLabv3+	Sentinel-1, Sentinel-2 (Óptico)	F1-Score: 0.93	Bacia do Rio Reno, Alemanha
(Silva; Santos, 2024)	Deslizamento	CNN (5-layer)	MDE, geologia, uso do solo, chuva (GPM)	AUC: 0.94	Serra do Mar, Brasil
(Rossi et al., 2023)	Deslizamento	ResNet-50	Fatores topográficos, NDVI, geologia	Acurácia: 95%	Apeninos, Itália
(Chen; Lee, 2024)	Deslizamento	Graph Neural Net	Rede de estradas, MDE, chuva	F1-Score: 0.89	Taiwan
(Davis et al., 2023)	Incêndio	SegNet	Sentinel-2 (MSI), Landsat 8	IoU: 0.94 (área queimada)	Califórnia, EUA
(García; Costa, 2024)	Incêndio	CNN-LSTM	MODIS, dados meteorológicos, topografia	RMSE: 3.5 km (propagação)	Galiza, Espanha
(Okafor et al., 2025)	Inundação	Attention U-Net	Imagens PlanetScope, SAR	IoU: 0.88	Bacia do Rio Níger, Nigéria


Fonte: Os autores

Para o mapeamento de **inundações**, o uso de imagens SAR (Sentinel-1) e arquiteturas de segmentação semântica (U-Net e variantes) é o padrão-ouro. Nos **deslizamentos**, o foco em mapas de susceptibilidade se vale de CNNs para integrar diversas camadas de dados estáticos e dinâmicos. Nos **incêndios**, há uma divisão clara: modelos de segmentação para mapear áreas queimadas e modelos espaço-temporais mais complexos, como CNN-LSTM, para a previsão de risco e propagação.

### 3.3 SÍNTESE DAS ARQUITETURAS E FONTES DE DADOS

Para visualizar as tendências gerais, analisou-se a frequência das arquiteturas de DL e das fontes de dados em todo o conjunto de artigos. A Figura 3 demonstra a hegemonia de modelos convolucionais, especialmente a família U-Net, que juntos somam quase metade de todas as aplicações.


Figura 3. Frequência de uso das arquiteturas de Deep Learning.



Fonte: Os autores

Do lado dos dados, a Figura 4 destaca o papel fundamental do programa Copernicus da Agência Espacial Europeia, com os satélites Sentinel-1 e Sentinel-2 sendo as fontes de dados mais utilizadas. Note que a soma das porcentagens ultrapassa 100%, pois muitos estudos utilizam múltiplas fontes de dados.

Figura 4. Frequência de uso das principais fontes de dados de satélite.



Fonte: Os autores

## 4 DISCUSSÃO

A análise sistemática da literatura recente revela um campo de pesquisa vibrante e em rápida expansão na interface entre Inteligência Artificial e a gestão de desastres. Os resultados quantitativos, que mostram um crescimento exponencial de publicações e uma clara especialização metodológica, são a base para uma análise mais profunda das tendências, dos desafios críticos e das oportunidades que definirão a próxima geração de sistemas de previsão de eventos extremos.

### 4.1 SÍNTESE E INTERPRETAÇÃO DAS PRINCIPAIS TENDÊNCIAS

Os resultados indicam que o campo está superando uma fase inicial exploratória para entrar em uma era de especialização. A escolha de modelos de *Deep Learning* e de fontes de dados não é aleatória, mas sim uma resposta direta e cada vez mais sofisticada à física e à fenomenologia de cada tipo de desastre. A predominância de arquiteturas de segmentação semântica, como a U-Net, combinadas com dados de radar (Sentinel-1) para o mapeamento de inundações (Müller et al., 2023; Zhang et al., 2024), é um exemplo claro dessa maturação. Trata-se da ferramenta computacional correta para a tarefa correta: a classificação densa de pixels (água vs. não-água) utilizando um sensor que opera independentemente das condições de nebulosidade que acompanham as tempestades.

De forma análoga, a aplicação massiva de Redes Neurais Convolucionais (CNNs) para o mapeamento de susceptibilidade a deslizamentos (Silva; Santos, 2024; Rossi et al., 2023) reflete o reconhecimento de que estes eventos são governados por uma complexa interação de fatores espaciais. As CNNs são inerentemente projetadas para aprender padrões e texturas em dados dispostos em grade, tornando-as a escolha natural para analisar a sobreposição de mapas de declividade, geologia, uso do solo e precipitação. Por fim, a emergência de modelos espaço-temporais mais complexos, como as arquiteturas híbridas CNN-LSTM para incêndios (García; Costa, 2024), sinaliza a fronteira mais avançada: a transição de uma análise reativa (mapear o que já queimou) para uma previsão proativa (antecipar para onde o fogo irá se propagar).

#### 4.2 DESAFIOS CRÍTICOS E LIMITAÇÕES ATUAIS

Apesar do progresso notável, nossa análise revela três desafios transversais que funcionam como gargalos, limitando o potencial de impacto real e a transição dos laboratórios de pesquisa para sistemas operacionais.

Primeiramente, o campo enfrenta o paradoxo do "Calcanhar de Aquiles" dos dados de treinamento. Embora tenhamos um dilúvio de dados de satélite (*Geospatial Big Data*), a maioria dos modelos de DL de alta performance é supervisionada, o que significa que eles dependem criticamente de grandes volumes de dados de "verdade terrestre" (*ground truth*), mapas precisos e verificados de eventos passados. Esses dados rotulados são escassos, caros para produzir e muitas vezes de qualidade questionável. Esta carência de dados de treinamento de alta qualidade é, talvez, o maior impedimento para o desenvolvimento de modelos verdadeiramente robustos e confiáveis.

Em segundo lugar, persiste o dilema da "caixa-preta" e a barreira da interpretabilidade. Modelos de *Deep Learning* podem atingir performances impressionantes, mas seus processos de decisão interna são opacos. Para um gestor de defesa civil ou um tomador de decisão, um mapa de risco sem uma explicação sobre *por que* uma determinada área é considerada perigosa tem utilidade limitada. A confiança é um fator fundamental para a adoção de qualquer sistema de alerta, e a falta de interpretabilidade dos modelos atuais gera um ceticismo compreensível. A pesquisa em Inteligência Artificial Explicável (XAI) aplicada a geociências ainda é incipiente e precisa ser urgentemente expandida.

Finalmente, os resultados expõem uma severa crise de generalização e transferibilidade. A forte concentração geográfica de estudos (Quadro 2) indica que os modelos são "super especializados", ou seja, otimizados para as condições geológicas, climáticas e de paisagem de suas áreas de estudo. Como demonstrado implicitamente pela falta de estudos, um modelo treinado para prever deslizamentos nos Apeninos italianos (Rossi et al., 2023) muito provavelmente apresentaria um desempenho medíocre se

aplicado diretamente na Serra do Mar brasileira (Silva; Santos, 2024). Essa incapacidade de "viajar" entre diferentes realidades geográficas limita drasticamente a escalabilidade das soluções e deixa as regiões mais vulneráveis e menos estudadas do Sul Global sem ferramentas adequadas.

#### 4.3 LACUNAS NA LITERATURA E DIRECIONAMENTOS PARA PESQUISAS FUTURAS

Os desafios identificados apontam diretamente para as lacunas que devem ser preenchidas pela próxima onda de pesquisas. Propomos quatro direções estratégicas:

- I. **Avançar para Modelos Híbridos (Física + IA):** O futuro não reside na substituição completa dos modelos baseados em processos físicos, mas na sua fusão com o *Deep Learning*. A pesquisa deve se concentrar no desenvolvimento de "modelos informados pela física" (*physics-informed neural networks*), que integram o conhecimento estabelecido sobre hidrologia, mecânica dos solos ou comportamento do fogo diretamente na arquitetura das redes neurais. Isso pode reduzir a dependência de dados rotulados e aumentar a capacidade de generalização dos modelos.
- II. **Explorar a Fusão com Novas Fontes de Dados:** A previsibilidade pode ser significativamente melhorada pela fusão de dados de satélite com fontes de dados em tempo real e de origem humana. A assimilação de informações de redes sociais georreferenciadas, dados de sensores da *Internet of Things* (IoT) e plataformas de ciência cidadã (*crowdsourcing*) pode diminuir o tempo de detecção e aumentar a precisão espacial dos alertas.
- III. **Focar na Quantificação de Incertezas:** Os sistemas operacionais de alerta exigem mais do que uma resposta determinística (risco/não risco). É crucial que os futuros modelos de DL forneçam também uma estimativa de sua própria incerteza. Abordagens como o *Deep Learning* Bayesiano, que geram previsões probabilísticas, precisam ser mais exploradas, pois permitem uma tomada de decisão mais informada e baseada no risco.
- IV. **Promover a Justiça Climática na Pesquisa:** A lacuna geográfica identificada em nossos resultados não é apenas científica, é também uma questão ética. É imperativo que a comunidade de pesquisa direcione esforços e recursos para desenvolver e validar modelos nas regiões do Sul Global, que são desproporcionalmente afetadas por eventos extremos e sub-representados na literatura científica. Isso exige a criação de conjuntos de dados locais e a colaboração estreita com pesquisadores e instituições dessas regiões.

## 5 CONCLUSÃO

Esta revisão sistemática demonstra a rápida maturação do uso de *Deep Learning* para a previsão de desastres, com uma crescente especialização de métodos para inundações, deslizamentos e incêndios. No entanto, o progresso em acurácia ainda não se traduz em ampla aplicação operacional

devido a desafios críticos: a carência de dados de treinamento de qualidade, a baixa interpretabilidade dos modelos de "caixa-preta" e sua limitada capacidade de generalização para novas regiões. O avanço do campo exige, portanto, um foco no desenvolvimento de modelos híbridos (IA + Física), interpretáveis e que priorizem as áreas geograficamente mais vulneráveis do planeta. Superar estas barreiras é a condição essencial para transformar o potencial tecnológico em ferramentas eficazes e equitativas para a resiliência climática global.

## REFERÊNCIAS

- CHEN, Y.; LEE, H. A graph neural network approach for landslide susceptibility mapping considering road network proximity in Taiwan. *Geomorphology*, v. 451, p. 109258, 2024.
- CHEN, Y.; LI, W. A review of landslide susceptibility mapping using deep learning: from data to models. *Earth-Science Reviews*, v. 246, p. 104595, 2023.
- DAVIS, M.; BROWN, A.; MILLER, C. Automated wildfire burn scar mapping in California using a SegNet deep learning model with bitemporal satellite imagery. *Remote Sensing of Environment*, v. 301, p. 114021, 2023.
- GARCÍA, P.; COSTA, J. A spatio-temporal CNN-LSTM model for wildfire spread prediction in Galicia, Spain, using MODIS and meteorological data. *International Journal of Wildland Fire*, v. 33, n. 4, p. 589-604, 2024.
- IPCC. Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Geneva: IPCC, 2023.
- JIANG, S. et al. A lightweight deep learning model for rapid flood mapping from Sentinel-1 SAR data. *International Journal of Applied Earth Observation and Geoinformation*, v. 128, p. 103730, 2024.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, 2015.
- MÜLLER, K.; SCHMIDT, F.; WAGNER, T. Sentinel-1 and Sentinel-2 data fusion with a DeepLabv3+ network for rapid flood mapping in the Rhine River basin. *IEEE Transactions on Geoscience and Remote Sensing*, v. 61, p. 5403315, 2023.
- OKAFOR, C.; ADEBAYO, J.; IBRAHIM, F. High-resolution flood extent mapping in the Niger River basin using PlanetScope imagery and an Attention U-Net model. *Journal of Hydrology*, v. 640, p. 132519, 2025.
- PAGE, M. J. et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, v. 372, n. 71, p. 1-8, 2021.
- REICHSTEIN, M. et al. Deep learning and process understanding for data-driven Earth system science. *Nature*, v. 566, n. 7743, p. 195–204, 2019.
- ROSSI, G.; CONTI, L.; LOMBARDI, F. Landslide susceptibility assessment in the Italian Apennines using a ResNet-50 model and multi-source geofactors. *Catena*, v. 230, p. 107654, 2023.
- SILVA, R.; SANTOS, M. A lightweight 5-layer convolutional neural network for landslide susceptibility mapping in Serra do Mar, Brazil. *Natural Hazards and Earth System Sciences*, v. 24, n. 5, p. 1701-1719, 2024.
- WORLD METEOROLOGICAL ORGANIZATION. State of the Global Climate 2023. Geneva: WMO, 2024. WMO-No. 1342.

WULDER, M. A. et al. The global Landsat archive and the evolution of Earth observation. Remote Sensing of Environment, v. 296, p. 113745, 2023.

ZHANG, L.; WANG, J.; LIU, Q. U-Net++ with dual attention mechanism for robust flood mapping in the Yangtze River basin using Sentinel-1 and ALOS PALSAR data. Water Resources Research, v. 60, n. 2, p. e2023WR035987, 2024.

ZHU, M. et al. A spatio-temporal deep learning model for daily wildfire danger prediction. International Journal of Wildland Fire, v. 33, n. 1, p. 1-15, 2024.