

CIDADES INTELIGENTES E RESILIENTES: UM ALGORITMO PREDITIVO PARA ANTECIPAÇÃO DE CATÁSTROFES CLIMÁTICAS E AMBIENTAIS

Arthur Bruno Marinho de Araújo

Aluno - Arquitetura e Urbanismo

arthur.araujo01@aluno.unifmetro.edu.br

Laysa Estefanny Oliveira Paulino

Aluna - Arquitetura e Urbanismo

laysa.paulino02@aluno.unifmetro.edu.br

Sarah Evelyn Rodrigues de Oliveira

Aluna - Arquitetura e Urbanismo

sarah.oliveira@aluno.unifmetro.edu.br

Kaio Gefferson de Almeida Mesquita

Orientador

kaio.mesquita@professor.unifmetro.edu.br

Área Temática: Inovação e Inteligência Artificial

Área de Conhecimento: Ciências Tecnológicas

Encontro Científico: XIII Encontro de Iniciação à Pesquisa

RESUMO

O trabalho parte do aumento recente de eventos climáticos extremos no Brasil, como as chuvas recordes no Litoral Norte de SP em fevereiro de 2023, para propor um algoritmo preditivo que integre dados climáticos, geográficos e socioeconômicos. O objetivo central é relacionar informações sobre mudanças climáticas com áreas de risco, identificando variáveis que impactam a vida urbana e o ambiente. A metodologia, de caráter descritivo e aplicada a municípios brasileiros com dados de 2024, compreende: coleta em órgãos oficiais; tratamento em Python; criação de um banco de dados integrado; treinamento de algoritmos de IA; e consolidação dos resultados para subsidiar decisões de gestores e defesa civil. Nos resultados, a Regressão Logística superou a Random Forest em todas as métricas. A Random Forest manteve desempenho inferior (acurácia média 0,9287; F1 0,7989), mas destacou variáveis críticas como coordenação municipal de defesa civil e investimentos em infraestrutura. As considerações finais indicam contribuição prática para priorização de ações e políticas urbanas, com a limitação principal ligada à disponibilidade/atualização dos dados. Recomenda-se ampliar fontes e integrar a solução a ferramentas de gestão.

Palavras-chave: Catástrofes climáticas; Inteligência Artificial; Previsão; Cidades inteligentes.

INTRODUÇÃO

As mudanças climáticas representam um dos maiores desafios do século XXI, manifestando-se de forma particularmente intensa nas áreas urbanas, onde a alta concentração populacional e as

alterações ambientais decorrentes da urbanização amplificam os riscos e impactos dos eventos climáticos extremos. O fenômeno do crescimento urbano acelerado, observado em diferentes países nas últimas décadas, tem criado um cenário de vulnerabilidade alarmante frente aos desastres naturais, evidenciando a necessidade urgente de estratégias eficazes e assertivas para a prevenção e mitigação desses riscos (IBGE, 2025).

No contexto brasileiro, a frequência e intensidade dos eventos climáticos extremos têm aumentado significativamente nas últimas três décadas, configurando um padrão preocupante que demanda a atenção de órgãos governamentais, institutos de pesquisa e agências meteorológicas, além de necessitarem de políticas imediatas. Esse crescimento de acontecimentos está intrinsecamente relacionado às alterações nos padrões climáticos globais e locais, agravados pela expansão urbana desordenada, impermeabilização do solo, formação de ilhas de calor urbano e deficiências no sistema de drenagem e infraestrutura urbana. As combinações desses fatores têm resultado em tragédias de proporções cada vez mais devastadoras, como demonstrado pelos recentes eventos que marcaram o cenário nacional (MARENGO, 2022; MAPBIOMAS, 2025).

Na cidade de Fortaleza, a estação chuvosa tem apresentado picos pluviométricos cada vez mais intensos e frequentes, revelando a vulnerabilidade da infraestrutura urbana. O INMET (2025), indicou a ocorrência de eventos com precipitação igual ou superior a 100 mm em 24 horas são recorrentes e estão associados a sistemas atmosféricos como a Zona de Convergência Intertropical (ZCIT), Zona de Convergência do Atlântico do Sul (ZCAS) e Complexos Convectivos de Mesoescala.

A escolha da região brasileira como estudo de caso para o desenvolvimento do algoritmo preditivo justifica-se por suas características climáticas particulares e pela disponibilidade de dados meteorológicos históricos robustos. O país apresenta padrões climáticos, até então, bem definidos, com períodos sazonais distintos que facilitam a identificação de tendências e a validação de modelos preditivos. Entretanto, dados recentes revelam tendências preocupantes, incluindo mudanças nos padrões de precipitação e umidade relativa. Essas mudanças, quando combinadas com o crescimento urbano acelerado, configuram um cenário de risco crescente. Além disso, a cidade enfrenta desafios típicos de centros urbanos brasileiros em crescimento, incluindo problemas de drenagem urbana, ocupação irregular de áreas de risco e vulnerabilidades socioeconômicas que amplificam os impactos dos eventos climáticos extremos (Nobre, 2016).

Diante desse panorama complexo e desafiador, o presente estudo tem por objetivo, desenvolver e validar um algoritmo supervisionado de aprendizado de máquina classificatório capaz de prever catástrofes climáticas em áreas urbanas através da integração e análise de dados climáticos, de infraestrutura, geográficos e socioeconômicos.

METODOLOGIA

O projeto iniciou-se com uma abrangente pesquisa sobre desastres urbanos e mudanças climáticas. Em seguida, foi feito o levantamento de dados climáticos, geográficos, urbanos e sociais. A proposta metodológica está resumida na Figura 1 em 4 etapas:

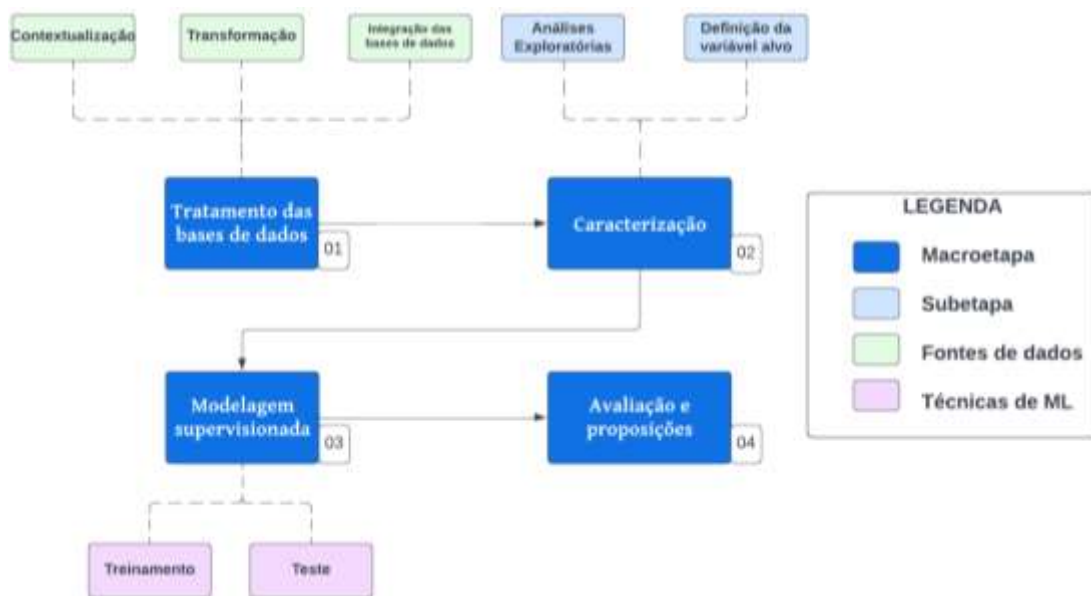


Figura 1 - Fluxograma de metodologia para funcionamento do algoritmo

Segundo o fluxograma da Figura 1, o processo segue as seguintes etapas: **(i) Levantamento de dados:** Coleta de dados históricos e abertos, informações climáticas, de relevo, uso do solo, dados socioeconômicos. Tratamento de informações utilizando linguagem Python para modelagem dos dados e previsões. As bases de dados utilizadas foram disponibilizadas pelo IBGE, INMET e Ministério das Cidades, culminando em dados climáticos, obras públicas de infraestrutura e sociodemográficos; **(ii) Caracterização:** Nesta etapa foram realizadas análises exploratórias a partir da integração das bases de dados (integração por código do município), buscando avaliar relações geográficas/climáticas com infraestrutura. Posteriormente foi definida a variável alvo, como sendo um indicador qualitativo que enquadra o município em níveis de possibilidade de ocorrência de desastres climáticos, sendo as seguintes categorias:

Muito Baixa (0%-20%), Baixa (20%-40%), Média (40%-60%), Alta (60%-80%), Muito Alta (80%-100%). Para definição dessas classes foi considerado o índice de preparo contra desastres e fatores climáticos. Posteriormente foi realizada a etapa (iii) **Treinamento de modelos**: os dados são utilizados para treinar algoritmos de aprendizado supervisionado, como *Random Forest* e regressão Logística para classificação com $k\text{-fold} = 5$, subdividindo a base de dados na proporção de 70:20:10 para conjuntos de treino, validação e teste respectivamente. O conjunto de validação foi utilizado para encontrar os melhores hiperparâmetros. Por fim, na etapa (iv) Avaliação e proposições, foram discutidas implicações sobre quais variáveis mais impactaram nos modelos de previsão e como elas afetam as relações urbanas e climatológicas. Assim, o modelo busca não apenas entregar dados, mas também intervenções e soluções, a curto prazo, como emissão de alertas preventivos em tempo real às populações em áreas de risco, a identificação imediata de zonas urbanas mais vulneráveis durante episódios de precipitação intensa, a disponibilização de painéis interativos de apoio à tomada de decisão por gestores públicos, a definição de rotas emergenciais para evacuação em situações críticas e a implementação de estratégias de comunicação comunitária voltadas à conscientização preventiva, e longo prazo, contribuir para o planejamento urbano sustentável a partir dos mapas de risco elaborados, adquirir investimentos em infraestrutura de drenagem e mobilidade urbana adaptada às mudanças climáticas e subsidiar a formulação de políticas públicas permanentes de prevenção e mitigação de desastres.

RESULTADOS E DISCUSSÃO

Foram coletados dados referentes à temperaturas e precipitação média anual, disponíveis no Instituto Nacional de Metrologia (INMET), e outros dados sobre equipamentos como Unidades de Corpo de Bombeiros, Coordenação Municipal de Defesa Civil (COMDEC), Núcleo de Defesa Civil, Plano Municipal de Redução de Riscos e Plano de Contingência, de diversos municípios do Brasil, divulgados pelo Ministério do Meio Ambiente e Mudança do Clima (MMA). Além de informações de valores e tipos de investimentos de obras públicas. Os dados coletados foram reunidos com diferentes graus de relevância para serem, então, processados por algoritmos de IA, apresentando-se a acurácia e relações entre as variáveis.

A análise dos modelos demonstrou desempenhos distintos entre a Regressão Logística e a *Random Forest*. A Regressão Logística (Figura 2) apresentou resultados superiores em todas as métricas avaliadas. Na validação cruzada (5 folds), obteve acurácia média de $0,9811 \pm 0,0039$ e F1-score de $0,9184 \pm 0,0179$. No teste *hold-out*, aplicado ao conjunto de teste, alcançou

acurácia de 0,9889 e F1-score de 0,9388. Esses valores refletem um desempenho geral excelente, especialmente nas categorias majoritárias (Alto e Muito Alto), onde os acertos foram significativos. A principal limitação observada foi na classe “Muito Baixo”, em que o *recall* caiu para 0,6429, revelando dificuldade na identificação de casos pouco representados.

```
=== LogisticRegression - Validação Cruzada (5 folds) ===
Acurácia (média ± dp): 0.9811 ± 0.0039
F1-macro (média ± dp): 0.9184 ± 0.0179

>>> Desempenho no conjunto de teste (hold-out)
Acurácia (teste): 0.9889
F1-macro (teste): 0.9388

Relatório de classificação (teste):
```

	precision	recall	f1-score	support
Alto	1.0000	0.9979	0.9989	474
Baixo	0.9103	0.9467	0.9281	75
Muito Alto	0.9968	1.0000	0.9984	308
Muito Baixo	1.0000	0.6429	0.7826	14
Médio	0.9814	0.9906	0.9860	213
accuracy			0.9889	1084
macro avg	0.9777	0.9156	0.9388	1084
weighted avg	0.9892	0.9889	0.9885	1084

Figura 2 - Resultados da Logistic Regression (Regressão Logística).

O Random Forest, por sua vez, apresentou robustez, porém com desempenho inferior em comparação à Regressão Logística. Na validação cruzada, atingiu acurácia média de $0,9287 \pm 0,0059$ e F1-score médio de $0,7989 \pm 0,0319$. Já no teste *hold-out*, obteve acurácia de 0,9419 e F1-score de 0,8338. Apesar de consistente nas classes majoritárias, apresentou queda acentuada na classe “Muito Baixo”, com recall de apenas 0,3571.

```
=== RandomForest - Validação Cruzada (5 folds) ===
Acurácia (média ± dp): 0.9287 ± 0.0059
F1-macro (média ± dp): 0.7989 ± 0.0319

>>> Desempenho no conjunto de teste (hold-out)
Acurácia (teste): 0.9419
F1-macro (teste): 0.8338

Relatório de classificação (teste):
```

	precision	recall	f1-score	support
Alto	0.9490	0.9810	0.9647	474
Baixo	0.8382	0.7600	0.7972	75
Muito Alto	0.9869	0.9805	0.9837	308
Muito Baixo	1.0000	0.3571	0.5263	14
Médio	0.8930	0.9014	0.8972	213
accuracy			0.9419	1084
macro avg	0.9334	0.7960	0.8338	1084
weighted avg	0.9410	0.9419	0.9396	1084

Figura 5 - Resultados da Random Forest.

De modo geral, a comparação final evidencia que a Regressão Logística superou a *Random Forest* em todos os aspectos, mostrando maior consistência e capacidade de generalização. Ainda assim, a *Random Forest* se destacou ao oferecer informações adicionais, como a relevância das variáveis no processo de predição, conforme apresentado na Figura 4. De acordo com o índice de importância, as variáveis que mais impactaram na previsão dos desastres foram a existência de coordenação municipal de defesa civil, a existência de usuários cadastrados NO S2iD - Sistema Integrado de Informações sobre Desastres, a existência de plano de contingência, a localização espacial do município e valor de investimento em infraestrutura.

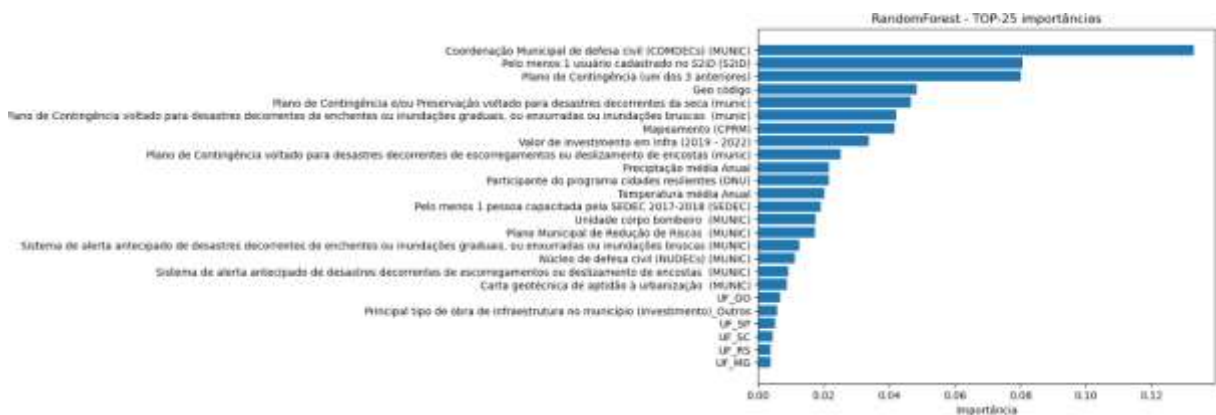


Figura 4 - Grau de relevância das variáveis.

As conclusões indicam que a Regressão Logística é o modelo mais adequado neste cenário, alcançando F1-score de 0,9388 e demonstrando excelente equilíbrio entre precisão e recall. O *Random Forest*, embora com menor desempenho, ressaltou a influência de fatores climáticos e institucionais como planos de contingência, sistemas de alerta e capacidade municipal, na previsão da ocorrência de desastres.

	modelo	acc_cv_mean	f1m_cv_mean	acc_test	f1m_test
0	LogisticRegression	0.9811	0.9184	0.9889	0.9388
1	RandomForest	0.9287	0.7989	0.9419	0.8338

Figura 5 - Comparação dos modelos.

Para aprimoramentos futuros, recomenda-se aplicar técnicas de balanceamento de classes (como SMOTE ou ajuste de pesos), a fim de melhorar a detecção das classes menos representadas.

CONSIDERAÇÕES FINAIS

O estudo demonstrou que é viável antecipar riscos de desastres climáticos em escala municipal ao integrar dados climáticos, territoriais, institucionais e de investimentos públicos em um pipeline analítico de IA. Entre os modelos testados, a Regressão Logística apresentou melhor desempenho (acurácia e F1 elevados), enquanto a Random Forest contribuiu para a interpretabilidade ao evidenciar fatores críticos como capacidade institucional (defesa civil, plano de contingência, cadastro no S2iD), localização e investimentos em infraestrutura. Esses achados fornecem subsídios práticos para gestores priorizarem ações de curto prazo (alertas, rotas de evacuação, comunicação comunitária) e planejamentos de longo prazo (drenagem, ocupação do solo e políticas permanentes de mitigação). As principais limitações residem na disponibilidade, atualização e balanceamento das classes nos dados, que afetaram especialmente a detecção de cenários “Muito Baixos”. Recomenda-se, como trabalhos futuros, ampliar fontes e granularidade espaço-temporal, aplicar técnicas de balanceamento (p.ex., SMOTE ou pesos), incorporar indicadores de vulnerabilidade social e de exposição, e integrar o sistema a painéis operacionais para suporte à decisão em tempo quase real. Assim, avança-se na direção de cidades mais seguras, resilientes e inteligentes.

REFERÊNCIAS

AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO (ANA). Disponível em: <https://www.gov.br/ana/>. Acesso em: 20 abr. 2025.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Disponível em: <https://www.ibge.gov.br/>. Acesso em: 09 mai. 2025.

INSTITUTO NACIONAL DE METEOROLOGIA (INMET). Disponível em: <https://portal.inmet.gov.br/>. Acesso em: 10 mai. 2025..

MAPBIOMAS. Projeto de Mapeamento Anual da Cobertura e Uso do Solo do Brasil. Disponível em: <https://mapbiomas.org/> Acesso em: 10 set. 2025.

MARENGO, J. A. et al. Eventos extremos e vulnerabilidades urbanas no Brasil: perspectivas sob mudanças climáticas. *Revista Brasileira de Meteorologia*, São Paulo, v. 37, n. 2, p. 245-262, 2022.

NOBRE, C. A. et al. Mudanças climáticas e planejamento urbano sustentável no Brasil. *Parcerias Estratégicas*, Brasília, v. 21, n. 42, p. 7-28, 2016.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS (ONU). *Habitat: diretrizes para cidades inteligentes e resilientes*. Nairobi: ONU-Habitat, 2020.