

XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HIDRÍCOS

IDENTIFICAÇÃO DE ÁREAS SUSCETÍVEIS A INUNDAÇÕES PLUVIAIS

NA BACIA DO RIO ITAJAÍ UTILIZANDO ALGORITMO DE

APRENDIZADO DE MÁQUINA

Manuel Mendoza Colos¹ ; Murilo Cesar Lucas² & Guilherme Palermo Coelho³

Resumen

Este estudio aplicó técnicas de teledetección y aprendizaje automático para identificar áreas susceptibles a inundaciones pluviales en la cuenca hidrográfica del río Itajaí, ubicada en el estado de Santa Catarina, Brasil. Se utilizó el algoritmo *Random Forest* (RF) debido a su robustez en el manejo de datos multidimensionales y su capacidad para modelar relaciones no lineales entre variables. Se consideraron nueve variables condicionantes, destacándose la altitud, la cobertura del suelo, la pendiente y la distancia al río. Los datos fueron obtenidos de fuentes como *Shuttle Radar Topography Mission* (SRTM), Sentinel-1, *Rainfall Estimates from Rain Gauge and Satellite Observations* (CHIRPS) y plataformas geoespaciales públicas. Tras un análisis de multicolinealidad, el modelo RF fue entrenado y validado con datos georreferenciados, alcanzando métricas de desempeño elevadas: un AUC de 0.99, precisión de 0.98, sensibilidad de 0.98 y F1-Score de 0.98. El análisis reveló que las áreas de baja altitud y proximidad a los ríos presentan mayor susceptibilidad, lo que concuerda con hallazgos previos. El mapa generado identificó zonas de riesgo con alta precisión, demostrando la efectividad de la metodología propuesta para apoyar la gestión de riesgos hidrológicos. El uso del RF se presentó como una alternativa eficiente frente a enfoques tradicionales, especialmente en contextos con escasez de datos primarios.

Resumo

Este estudo aplicou técnicas de sensoriamento remoto e aprendizado de máquina para identificar áreas suscetíveis a inundações pluviais na bacia hidrográfica do Rio Itajaí, localizada em Santa Catarina, Brasil. Utilizou-se o algoritmo *Random Forest* (RF) devido à sua robustez na manipulação de dados multidimensionais e na modelagem de relações não lineares entre variáveis. Foram consideradas nove variáveis condicionantes, destacando-se altitude, cobertura do solo, declividade e distância ao rio. Os dados foram obtidos de fontes como *Shuttle Radar Topography Mission* (SRTM), Sentinel-1, *Rainfall Estimates from Rain Gauge and Satellite Observations* (CHIRPS) e plataformas geoespaciais públicas. Após análise de multicolinearidade, o modelo RF foi treinado e validado com dados georreferenciados, alcançando métricas de desempenho elevadas: AUC de 0,99, precisão de 0,98, sensibilidade de 0,98 e F1-Score de 0,98. A análise revelou que áreas de baixa altitude e proximidade de rios possuem maior suscetibilidade, corroborando a literatura. O mapa gerado identificou zonas de risco com alta acurácia, evidenciando a efetividade da metodologia proposta para apoiar a gestão de riscos hidrológicos. O uso do RF demonstrou ser uma alternativa eficiente às abordagens tradicionais, especialmente em contextos com escassez de dados primários.

Palavras-Chave: Cidades Resilientes, Mapeamento, Segurança hídrica, Sensoriamento remoto.

1) Afiliação: Faculdade de Tecnologia, Unicamp, R. Paschoal Marmo, 1888, Jardim Nova Itália, 13.484-332, Limeira – SP, m249533@g.unicamp.br

2) Afiliação: Faculdade de Tecnologia, Unicamp, R. Paschoal Marmo, 1888, Jardim Nova Itália, 13.484-332, Limeira – SP, mlucas@gmail.com

3) Afiliação: Faculdade de Tecnologia, Unicamp, R. Paschoal Marmo, 1888, Jardim Nova Itália, 13.484-332, Limeira – SP, gpc Coelho@unicamp.br

INTRODUÇÃO

Inundações pluviais são um dos desastres naturais mais frequentes e destrutivos, com impactos significativos na economia, deslocamento de pessoas e danos severos à infraestrutura (Hasanuzzaman et al., 2022; Maharjan et al., 2024). Estima-se que mais de 170 milhões de pessoas sejam afetadas por esses tipos de eventos globalmente a cada ano, que são responsáveis por mais de 60% das mortes associadas a desastres naturais (Razavi-Termeh et al., 2023). O aumento das inundações está principalmente relacionado às mudanças climáticas, ao uso e ocupação inadequados do solo e ao crescimento urbano desordenado (Wang et al., 2024). No Brasil, as inundações estão entre os desastres mais recorrentes, segundo o Sistema Integrado de Informações sobre Desastres (S2ID) (Kephart et al., 2025), especialmente na região Sul. Por exemplo, o Estado de Santa Catarina, especificamente a bacia do Rio Itajaí, tem sido afetada por eventos recorrentes, afetando municípios como Itajaí, Ilhota, Brusque, Blumenau, Taió e Rio do Sul.

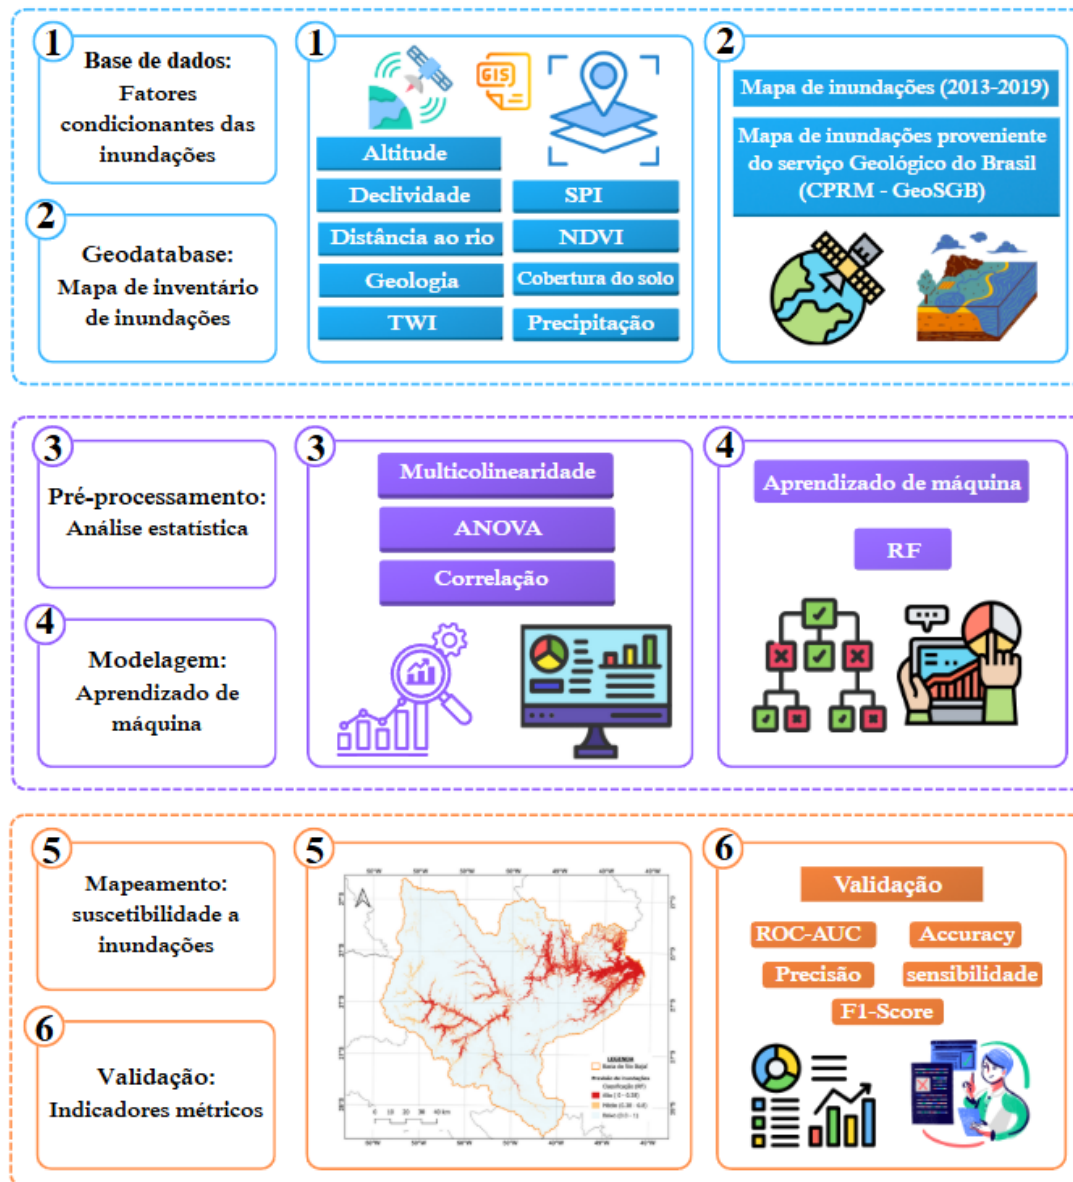
Diante desse cenário, o mapeamento de suscetibilidade a inundações é uma ferramenta fundamental na gestão de riscos e na redução de danos (Razavi-Termeh et al., 2023). No entanto, abordagens tradicionais, como modelos baseados em física e análise de decisão multicritério, apresentam limitações, pois exigem grandes quantidades de dados de campo e o julgamento de especialistas em topografia, uso do solo e precipitação, entre outros (Hasanuzzaman et al., 2022). Isso dificulta sua aplicação em larga escala e compromete a capacidade de generalização para outras regiões com características distintas ou escassez de dados. Por outro lado, algoritmos de aprendizado de máquina são eficazes para superar essas limitações, permitindo o processamento de grandes volumes de dados e a detecção de padrões espaciais complexos com maior acurácia (Razavi-Termeh et al., 2023). Dentre eles, destaca-se o modelo *Random Forest* (RF), que tem demonstrado desempenho superior para mapeamento de suscetibilidade às inundações, por causa da sua capacidade de manipular dados multidimensionais e capturar relações não lineares entre variáveis (Salvati et al., 2023).

MATERIAIS E MÉTODOS

O estudo seguiu uma metodologia estruturada e sequencial (Figura 1), com o objetivo de mapear e classificar áreas SUSCETÍVEIS a inundação na bacia do Rio Itajaí, usando o modelo RF. Na primeira etapa, foram obtidos e organizados os atributos estáticos (físico-geográficos) e atributos dinâmicos (variáveis). Além disso, foi selecionada uma base de dados geoespaciais de manchas de inundação para ser usada como *ground-truth*. Na segunda etapa, foi realizada a análise estatística de multicolinearidade e correlação entre os atributos e variáveis, seguida do treinamento e teste do modelo RF. Na terceira etapa, o modelo treinado foi aplicado à área de estudo para gerar mapas de suscetibilidade às inundações e avaliar o seu desempenho (Figura 1).

Para mapear áreas suscetíveis à inundação, é fundamental inspecionar aquelas que foram afetadas por eventos anteriores. As áreas detectadas como inundadas foram validadas com a mancha vetorial de inundação disponibilizada pelo Serviço Geológico do Brasil, por meio da plataforma GeoSGB (<https://geoportal.sgb.gov.br/geosgb/>), com dados referentes ao Estado de Santa Catarina (<https://acervo.arquivopublico.sc.gov.br/>). Além disso, foram usados relatos de notícias (históricas) de inundações em municípios como Blumenau, Itajaí, Ilhota, Gaspar e Rio do Sul. Também foi utilizada a base de dados do município de Itajaí, disponível em: <https://arcgis.itajai.sc.gov.br/portal/apps/webappviewer/index.html?id=4e097e762ffc484e84648905f0d75347>.

Figura 1 – Protocolo para mapeamento de áreas SUSCETÍVEIS às inundações pluviais. Primeira etapa (cor azul), segunda etapa (cor roxo) e terceira etapa (cor laranja). As numerações indicam processos, métodos ou fontes de dados dentro de cada etapa.

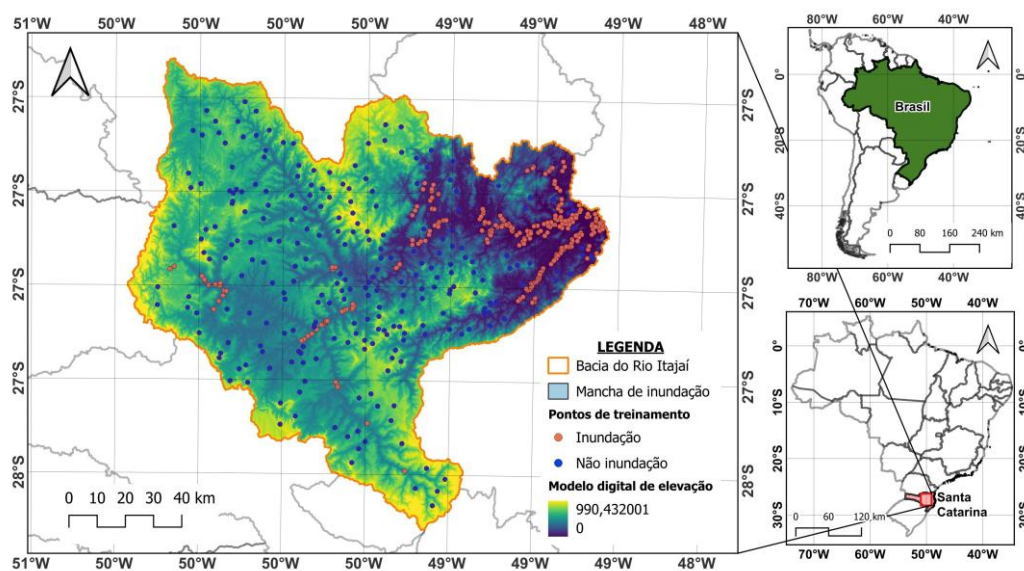


Área de estudo

A bacia hidrográfica do Rio Itajaí (sub-bacia 83), localizada no Estado de Santa Catarina, Brasil (Figura 2), é uma das regiões mais afetadas por inundações no país, em razão de sua topografia plana e presença de vales aluviais. Com aproximadamente 14.849,8 km², de acordo os dados de (IBGE), possui uma população estimada de 1.434.327 habitantes, com densidade demográfica de 94,68 hab/km². O uso e ocupação do solo caracteriza-se pela predominância de áreas urbanizadas como nos municípios de Blumenau, Itajaí e Brusque e zonas agrícolas destinadas ao cultivo de milho, soja, feijão e hortaliças. Ainda conserva importantes remanescentes de Mata Atlântica, cobrindo cerca de 6.219 km², o que representa 40,62% de sua área total (Luis et al., 2015). O clima é subtropical úmido, com classificação Cfa (verões quentes) e Cfb (verões amenos), apresentando temperaturas médias

anuais entre 14 °C e 20 °C e uma precipitação média de 1.550 mm, fatores que contribuem para a recorrência de eventos hidrológicos extremos.

Figura 2– Localização geográfica da bacia hidrográfica do Rio Itajaí. Os pontos em cor vermelho e azul indicam, respectivamente, áreas inundadas e não inundadas. Esses pontos de inundação foram inseridos a partir da base de dados de manchas de inundação do Serviço Geológico do Brasil.

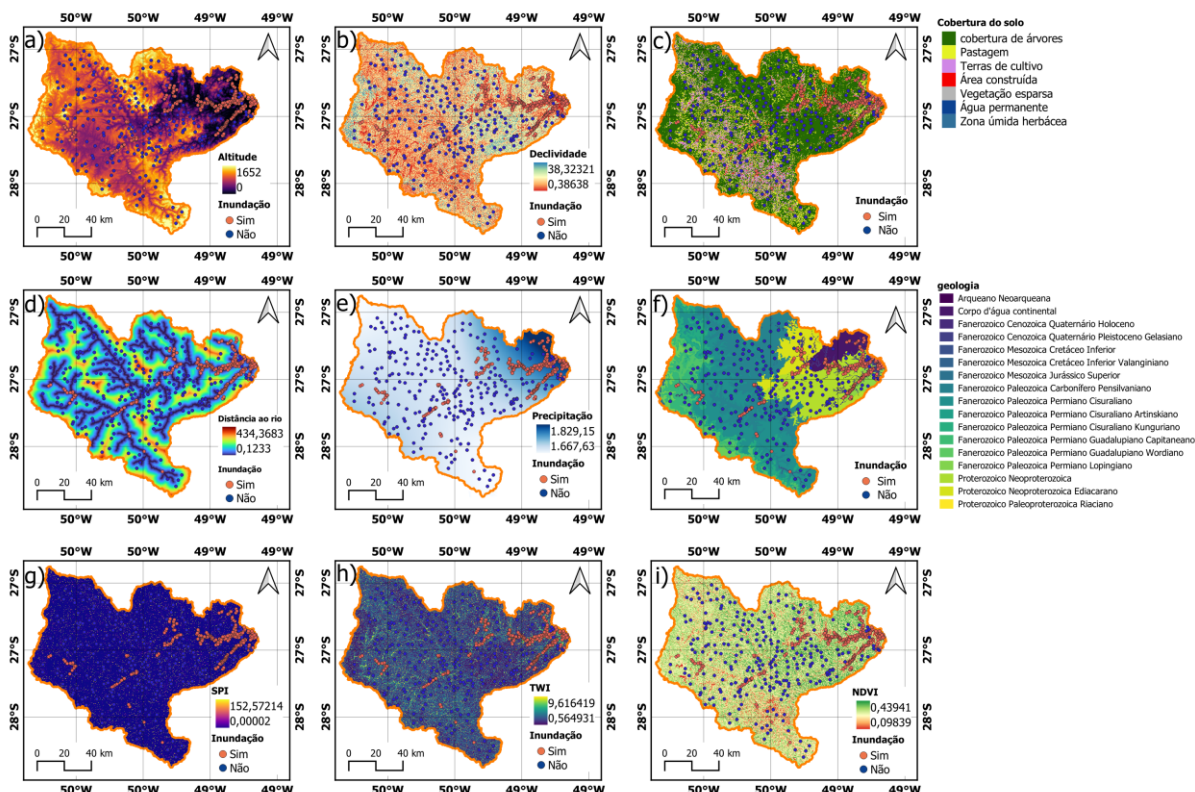


Atributos de suscetibilidade às inundações

A suscetibilidade a inundações refere-se à probabilidade de uma área geográfica ser afetada por uma inundação, com base em suas características físicas, topográficas e ambientais intrínsecas, sem considerar variáveis temporais, como a precipitação (Wang et al., 2024). A suscetibilidade indica a propensão de uma área a inundações devido a fatores como declividade, tipo de solo, cobertura vegetal, altitude, proximidade de corpos d'água e outras condições geológicas ou morfométricas, que permitem a identificação de áreas vulneráveis antes que eventos hidrológicos ocorram (Widya et al., 2024).

Nove atributos foram identificados para o mapeamento de áreas propensas a inundações; as mais notáveis são: altitude, declividade, distância do rio, geologia, cobertura do solo, precipitação média anual, Índice Padronizado de Precipitação (SPI), Índice Topográfico de Umidade (TWI), Índice de Vegetação por Diferença Normalizada (NDVI). Um resumo das características e fonte dos atributos está apresentado no Quadro 1, enquanto a representação espacial dos mesmos é apresentada na Figura 4. Vários estudos sobre bacias hidrográficas mostram que baixas altitudes favorecem o acúmulo de água, enquanto a declividade influencia as taxas de escoamento superficial (Norallahi & Seyed, 2021). A distância do rio determina as áreas mais próximas da planície de inundação do rio (Widya et al., 2024). O TWI permite estimar o acúmulo de umidade do solo, enquanto o SPI avalia a capacidade de transferência de água (Saleh et al., 2022).

Figura 4 – Fatores condicionantes das inundações: (a) Altitude; (b) Cobertura do solo; (c) Declividade; (d) Distância ao rio; (e) Geologia; (f) Precipitação; (g) Índice Padronizado de Precipitação (SPI); (h) Índice Topográfico de Umidade (TWI); e (i) Índice de Vegetação por Diferença Normalizada (NDVI).



A formação geológica influencia a capacidade de infiltração, a permeabilidade e a capacidade de retenção de água (Widya et al., 2024). A cobertura do solo influencia diretamente a infiltração e a capacidade de escoamento. Superfícies impermeáveis, como áreas urbanas, aumentam o risco de inundações, enquanto áreas vegetadas o reduzem. O NDVI, por sua vez, permite avaliar a densidade da vegetação, que está relacionada à vitalidade, biomassa verde ou atividade fotossintética.

Quadro 1 – Características dos atributos usados no modelo *Random Forest*.

ID	Variáveis	Fonte	Escala	Descrição e extração
1	Altitude, Declividade, Distância ao rio, Índice Topográfico de Umidade (TWI), e Índice de Precipitação Padronizado (SPI)	Modelo de elevação digital (MED)	30 × 30	<i>Shuttle Radar Topography Mission</i> (SRTM) https://search.asf.alaska.edu/
2	Geologia	Atlas geológico	1:100.000	Serviço Geológico do Brasil-GeoSGB https://geoportal.sgb.gov.br/geosgb/
3	Cobertura do solo	ESA <i>WorldCover</i> V2 2021	10 × 10	Mapeamento da cobertura terrestre global https://esa-worldcover.org/en
4	Índice de Vegetação por Diferença Normalizada (NDVI)	Sentinel-2	10 × 10	<i>Google Earth Engine</i> https://earthengine.google.com/platform/
5	Precipitação média anual	<i>Climate Hazards Group InfraRed Precipitation with Station data</i> (CHIRPS)	1:5.560	<i>Google Earth Engine</i> https://earthengine.google.com/platform/

Random Forest (RF)

O modelo de *Random Forest* (RF), proposto por Breiman (2001), é um modelo de aprendizado de máquina comumente utilizado para resolver problemas de classificação e regressão. Este método melhora a precisão de classificadores fracos usando uma técnica conhecida como *bagging* e incorpora a abordagem de “seleção aleatória de características”. Durante o processo de treinamento, o RF gera diversas árvores de decisão por meio de amostragem com substituição (Islam et al., 2023; Rahman et al., 2025). Este algoritmo também mitiga potenciais vieses ao escolher aleatoriamente registros de entrada e parâmetros preditivos durante o treinamento, evitando *overfitting*.

No RF, a predição é obtida pela agregação das predições de diversas árvores de decisão. A predição final é o resultado da votação majoritária entre as predições das árvores individuais. O modelo RF foi implementado em Python utilizando o *Jupyter Notebook*, utilizando imagens matriciais com resolução espacial de 30 metros, representando diversos condicionantes associados à ocorrência de inundações. A partir dos atributos de entrada, foi construído um conjunto de dados composto por pontos georreferenciados previamente classificados como áreas inundadas (1) e não inundadas (0), os quais foram organizados em um *dataFrame*.

Com base em práticas metodológicas comumente aceitas em estudos semelhantes (Widya et al., 2024), o *dataframe* foi dividido em dois subconjuntos, com 70% dos dados alocados para o treinamento do modelo e os 30% restantes para a validação, permitindo uma avaliação robusta de sua capacidade preditiva. O modelo treinado foi aplicado à área de estudo, gerando um valor contínuo de probabilidade de inundação por pixel, variando de 0 a 1, com valores próximos a 1 indicando maior suscetibilidade a inundações. Essas probabilidades foram então reclassificadas em três categorias discretas: baixa, média e alta suscetibilidade, utilizando o método estatístico *Natural Breaks* (Jenks) (Razavi-Termeh et al., 2023). Esse procedimento agrupa os dados de acordo com descontinuidades naturais em sua distribuição, permitindo que as informações contínuas sejam transformadas em classes claramente diferenciadas como baixo, médio e alto.

Avaliação do desempenho do modelo RF

A avaliação de desempenho de um modelo de classificação é uma etapa fundamental no desenvolvimento de modelos preditivos, especialmente em estudos de suscetibilidade a inundações (Darabi et al., 2022). Neste trabalho, métricas amplamente aceitas foram utilizadas para validar a eficácia do modelo RF, incluindo Área Sob a Curva (AUC), Accuracy, Precisão, Sensibilidade (Recall), F1-Score e análise de matriz de confusão (Hasanuzzaman et al., 2022; Widya et al., 2024). Essas métricas permitem uma avaliação abrangente da capacidade do modelo de classificar corretamente as observações e distinguir entre áreas afetadas e não afetadas por inundações.


O valor da AUC (Área Sob a Curva) corresponde à curva ROC e representa graficamente a capacidade do modelo de discriminar entre classes. Um valor próximo a 1,0 indica alta capacidade de classificação, enquanto um valor próximo a 0,5 reflete classificação aleatória. As métricas de precisão, sensibilidade e F1-Score foram calculadas a partir da matriz de confusão, fornecendo uma visão detalhada do equilíbrio entre os erros Tipo I (quando o modelo aponta risco de inundação onde não há) e Tipo II (quando o modelo não detecta uma área que realmente pode ser inundada). Essas ferramentas garantem uma avaliação robusta e confiável do desempenho do modelo *Random Forest* na identificação de áreas com alta suscetibilidade a inundações.

RESULTADOS E DISCUSSÃO

Na presente análise, nove variáveis preditoras foram consideradas, conforme indicado na literatura, para mapear a suscetibilidade a inundações, utilizando técnicas de sensoriamento remoto e

Random Forest. Os resultados do modelo mostraram que a altitude do terreno, seguida pela cobertura do solo, declive e distância ao rio, foram as variáveis mais importantes dentro do modelo (Figura 5). Em particular, a altitude foi posicionada como o fator mais determinante, o que é consistente com estudos anteriores, nos quais a altitude do terreno influencia diretamente o padrão de escoamento superficial e o acúmulo de água (Widya et al., 2024)

Figura 5 – Resultado da importância dos fatores no modelo *Random Forest*.



Essa relevância da altitude encontra suporte estatístico na forte correlação negativa com a precipitação ($r = -0,77$) e na correlação positiva com a distância ao rio ($r = 0,67$). Essas relações refletem um padrão topográfico característico de bacias hidrográficas, no qual áreas elevadas tendem a apresentar menor acúmulo de água superficial e, conseqüentemente, menor suscetibilidade a inundações (Widya et al., 2024). Da mesma forma, uma análise de multicolinearidade foi aplicada para avaliar a independência estatística entre as variáveis preditoras, onde o Fator de Inflação da Variância (VIF) é apresentado na Tabela 2, com um intervalo de 1,106 a 5,344. Altitude, embora tenha registrado o maior VIF (5,344), indicando certo grau de redundância com outras variáveis do modelo, conforme aponta (Razavi-Termeh et al., 2023) foi mantida no estudo, pois a *Random Forest* é robusta o suficiente para funcionar até $VIF < 10$ (Ilia et al., 2022). As demais variáveis apresentaram valores de VIF menores que 4, o que garante baixa colinearidade e adequada estabilidade do modelo. Por sua vez, os valores de tolerância (TOL) corroboram essa observação, sendo menores em variáveis com maior multicolinearidade.


Tabela 2 – Resultados de teste de multicolinearidade

N	Fatores de inundação	TOL	VIF
1	Altitude	0.187	5.344
2	Geologia	0.576	1.735
3	Cobertura do solo	0.278	3.594
4	NDVI	0.410	2.437
5	Precipitação anual média	0.339	2.944
6	Declividade	0.451	2.216

7	SPI	0.903	1.106
8	TWI	0.559	1.786
9	Distância do rio	0.491	2.032

Em relação ao comportamento hidrológico, a declividade variável do terreno também desempenhou um papel relevante. Este achado é consistente com pesquisas anteriores que reconhecem a declividade como um fator-chave na dinâmica do fluxo superficial e na formação de inundações (Hasanuzzaman et al., 2022; Widya et al., 2024). Em regiões com declive acentuado, a água tende a drenar rapidamente, diminuindo o acúmulo; por outro lado, em áreas planas ou com pouca declividade, a água tende a estagnar, aumentando o risco de inundações. Da mesma forma, a distância do rio foi confirmada como um fator crucial, visto que áreas próximas a corpos d'água estão mais expostas a transbordamentos fluviais.

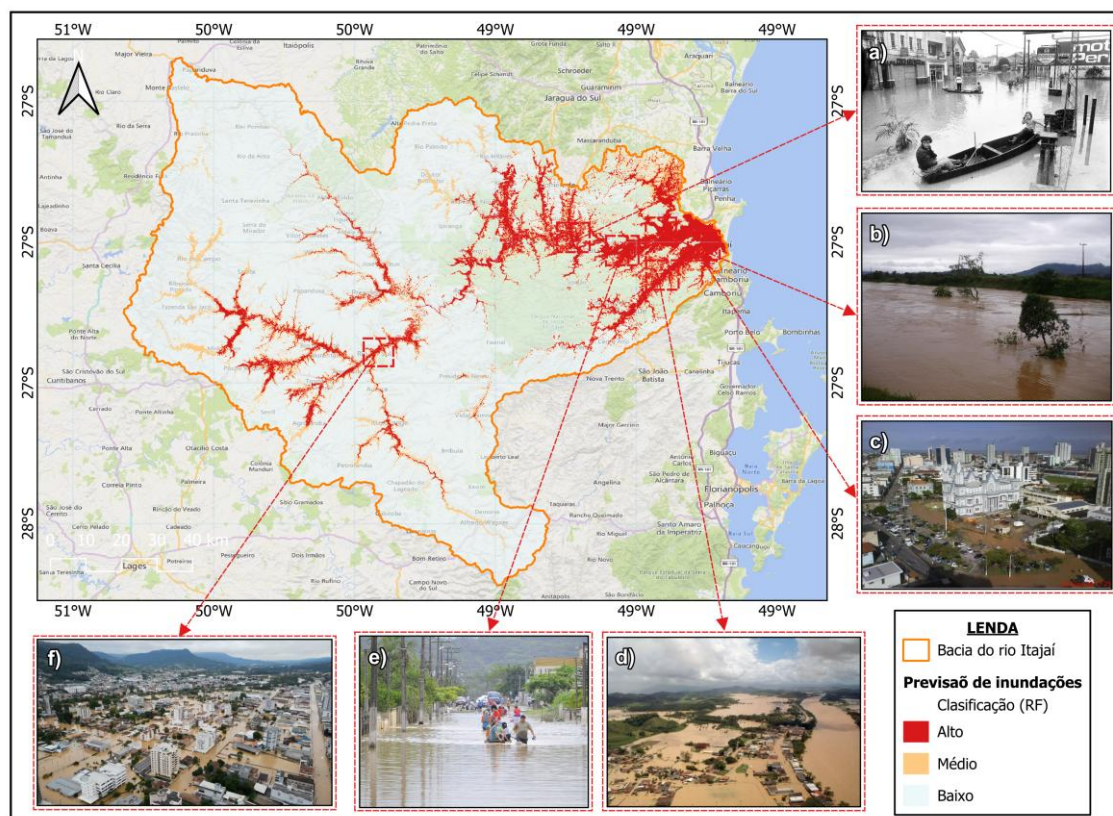
Figura 6 – Gráfico ROC do modelo *Random Forest*



O desempenho do modelo foi avaliado por meio de métricas estatísticas padrão. O algoritmo *Random Forest* obteve um valor de AUC (ROC) de 0,9993 (Figura 6), o que indica uma capacidade quase perfeita de classificação. A precisão geral (Accuracy) foi de 0,9867, acompanhada por valores igualmente elevados de precisão (0,9867), sensibilidade (Recall = 0,9867) e F1-Score (0,9867). Esses resultados demonstram um excelente desempenho do modelo, com equilíbrio entre a detecção de áreas realmente suscetíveis a inundações e a minimização de falsos negativos, fatores essenciais para a previsão de risco.

Os resultados obtidos são apresentados na Figura 7, que representa a distribuição espacial das áreas com alta, média e baixa suscetibilidade a inundações. Além disso, nas áreas com alta suscetibilidade, foi realizada uma busca detalhada de informações, a partir da qual se constatou que essas áreas foram afetadas em diversas ocasiões. Alguns municípios situados dentro dessas áreas de alta suscetibilidade a inundações são destacados no mapa de susceptibilidade.

Figura 7 – Mapa de suscetibilidade a inundações gerado com o modelo de *Random Forest*: (a) Município de Blumenau (ano de 1983); (b) Município de Ilhota (ano de 2008); (c) Município de Itajaí (ano de 2008); (d) Município de Itajaí (ano de 2008); (e) Município de Gaspar (ano de 2008); e (f) Município de Rio do Sul (ano de 2023)



CONCLUSÃO

Este estudo demonstrou que o uso do algoritmo Random Forest, combinado com dados geoespaciais e técnicas de sensoriamento remoto, permite uma modelagem altamente precisa da suscetibilidade a inundações na bacia do rio Itajaí. As variáveis físicas e ambientais analisadas, como a altitude, a cobertura do solo e a distância do rio, foram fundamentais para a identificação das zonas de risco. Os resultados obtidos reforçam o potencial das abordagens baseadas em aprendizado de máquina para apoiar o planejamento territorial e a gestão preventiva frente a eventos hidrometeorológicos extremos. Além disso, as áreas classificadas como de alta suscetibilidade a inundações, como os municípios de Itajaí, Gaspar, Ilhota, Blumenau e Rio do Sul, sofreram repetidas inundações ao longo dos anos, como se observa na Figura 7. Estes dados corroboram a necessidade urgente de estratégias de gestão integrada para mitigar os impactos das inundações.

AGRADECIMENTO

Este trabalho contou com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo financiamento via Projeto CNPq Universal (Processo nº 403292/2023-9) e do Fundo de Apoio ao Ensino, à Pesquisa e à Extensão (FAEPEX) da UNICAMP (Processo nº 3111/23). O primeiro autor agradece ao CNPq pela concessão de bolsa de mestrado.

REFERÊNCIAS

- BREIMAN, L. (2001). “*Random Forest. Mach Learn*”, 45, 5–32.
- DARABI, H., RAHMATI, O., NAGHIBI, S. A., MOHAMMADI, F., AHMADISHARAF, E., KALANTARI, Z., TORABI HAGHIGHI, A., SOLEIMANPOUR, S. M., TIEFENBACHER, J. P., & TIEN BUI, D. (2022). “*Development of a novel hybrid multi-boosting neural network model for spatial prediction of urban flood*”. *Geocarto International*, 37(19), 5716–5741.
- HASANUZZAMAN, M., ISLAM, A., BERA, B., & SHIT, P. K. (2022). “*A comparison of performance measures of three machine learning algorithms for flood susceptibility mapping of river Silabati (tropical river, India)*”. *Physics and Chemistry of the Earth*, 127.
- ILIA, I., TSANGARATOS, P., TZAMPOGLOU, P., CHEN, W., & HONG, H. (2022). “*Flash flood susceptibility mapping using stacking ensemble machine learning models*”. *Geocarto International*, 37(27), 15010–15036.
- ISLAM, A. R. M. T., BAPPI, M. M. R., ALQADHI, S., BINDAJAM, A. A., MALLICK, J., & TALUKDAR, S. (2023). “*Improvement of flood susceptibility mapping by introducing hybrid ensemble learning algorithms and high-resolution satellite imageries*”. *Natural Hazards*, 119(1), 37.
- KEPHART, J. L., BILAL, U., GOUVEIA, N., SARMIENTO, O. L., SHINGARA, E., RANGEL MORENO, K., BAKHTSIYARAVA, M., RODRIGUEZ, J. P., AYALA, S., CARRASCO-ESCOBAR, G., & DIEZ ROUX, A. V. (2025). “*Social disparities in neighborhood flood exposure in 44,698 urban neighborhoods in Latin America*”. *Nature Cities*, 2(3), 246–253.
- LUIS, J., MACHADO, F., & MARCUZZO, F. F. N. (2015). “*Aquíferos da bacia hidrográfica do rio itajaí no estado de santa catarina - aquifers of river itajaí basin in santa catarina state - Hydrographische schlüssel des Itajaí-flusses*”.
- MAHARJAN, M., TIMILSINA, S., AYER, S., SINGH, B., MANANDHAR, B., & SEDHAIN, A. (2024). “*Flood susceptibility assessment using machine learning approach in the Mohana-Khutiya River of Nepal*”. *Natural Hazards Research*, 4(1), 32–45.
- NORALLAHI, M., & SEYED KABOLI, H. (2021). “*Urban flood hazard mapping using machine learning models: GARP, RF, MaxEnt and NB*”. *Natural Hazards*, 106(1), 119–137.
- RAHMAN, M. M., KAMRUZZAMAN, M., DEB, L., & ISLAM, H. M. T. (2025). “*Flood mapping, damage assessment, and susceptibility zonation in northeastern Bangladesh in 2022 using geospatial datasets*”. *Progress in Disaster Science*, 25.
- RAZAVI-TERMEH, S., SADEGHI-NIARAKI, A., & CHOI, S. (2023). “*A new approach based on biology-inspired metaheuristic algorithms in combination with Random Forest to enhance the flood susceptibility mapping*”. *Journal of Environmental Management*, 345.
- SALEH, A., YUZIR, A., SABTU, N., ABUJAYYAB, S. K. M., BUNMI, M. R., & PHAM, Q. B. (2022). “*Flash flood susceptibility mapping in urban area using genetic algorithm and ensemble method*”. *Geocarto International*, 37(25), 10199–10228.
- SALVATI, A., NIA, A. M., SALAJEGHEH, A., GHADERI, K., ASL, D. T., AL-ANSARI, N., SOLAIMANI, F., & CLAGUE, J. J. (2023). “*Flood susceptibility mapping using support vector regression and hyper-parameter optimization*”. *Journal of Flood Risk Management*, 16(4).
- WANG, Z., LYU, H., & ZHANG, C. (2024). “*Urban pluvial flood susceptibility mapping based on a novel explainable machine learning model with synchronous enhancement of fitting capability and explainability*”. *Journal of Hydrology*, 642.
- WIDYA, L. K., REZAIE, F., LEE, W., LEE, C. W., NURWATIK, N., & LEE, S. (2024). “*Flood susceptibility mapping of Cheongju, South Korea based on the integration of environmental factors using various machine learning approaches*”. *Journal of Environmental Management*, 364.