

XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HIDRÍCOS

APRENDIZADO DE MÁQUINA POSITIVO E NÃO ROTULADO PARA O MAPEAMENTO DE SUSCETIBILIDADE A INUNDAÇÕES

Marcos Roberto Benso¹, Marina Batalini de Macedo², Anaí Floriano Vasconcelos¹, Maria Elisa Leite Costa³, Alan Vaz Lopes³, Javier Tomasella⁴, Beliana Cavalcante Sawada de Carvalho⁵, Thiago Souza Biscaro⁴, Maria Clara Fava¹

Abstract: This study employs a machine learning methodology for classifying flood susceptibility using flood inventory data. One of the main challenges resides in the fact that the database only provides flood occurrence (positive label), while, for binary classification, it is necessary to provide to the algorithm also the points of non-occurrence (negative label). Here we use a method called positive and unlabeled classification that consists in two steps. In the first step, a random set of points in the study area is generated and combined with the observed dataset. A machine learning algorithm is trained to estimate relatively reliable negative (RRN) labels. A new dataset is built consisting of observed positive labels and RRN labels and is used to train machine learning models to probabilistically predict flood occurrences. The study demonstrates that the positive and unlabeled classification (PU learning) method contributes significantly to the model performance, with kappa values increasing from 0.4 to 0.8. The susceptibility map validation was performed based on the CAFLOOD 2D model and comparisons with Height Above Nearest Drainage (HAND) values. The results indicate that the machine learning-based model was able to identify a wider range of areas potentially susceptible to flooding, including regions that were not represented in the observed occurrence data.

Resumo: Este estudo utiliza uma metodologia de aprendizado de máquina para classificar a suscetibilidade a inundações usando dados de inventário de inundações. Um dos principais desafios está no fato de que o banco de dados fornece apenas ocorrências de inundações (rótulo positivo), enquanto, para a classificação binária, é necessário fornecer ao algoritmo também os pontos de não ocorrência (rótulo negativo). Neste trabalho, utilizamos um método chamado "classificação positiva e não rotulada", que consiste em duas etapas. Na primeira etapa, um conjunto aleatório de pontos na área de estudo é gerado e combinado com o conjunto de dados observados. Um algoritmo de aprendizado de máquina é treinado para estimar rótulos negativos relativamente confiáveis (RRN). Um novo conjunto de dados é construído, consistindo de rótulos positivos observados e rótulos RRN, e é usado para treinar modelos de aprendizado de máquina para prever probabilisticamente ocorrências de inundações. O estudo demonstra que o método de classificação positiva e não rotulada (PU learning) contribui significativamente para o desempenho do modelo, com valores de kappa aumentando de 0,4 a 0,8. A validação do mapa de suscetibilidade foi realizada com base no modelo CAFLOOD 2D e comparações com valores de Altura acima da drenagem mais próxima

¹ Universidade Federal de São Carlos

² Universidade Federal de Itajubá

³ Agência Nacional de Águas e Saneamento Básico

⁴ Instituto Nacional de Pesquisas Espaciais

⁵ Universidade Estadual Paulista

(HAND). Os resultados indicam que o modelo baseado em aprendizado de máquina foi capaz de identificar uma gama mais ampla de áreas potencialmente suscetíveis à inundações, incluindo regiões que não estavam representadas nos dados de ocorrência observados.

Palavras-Chave – inundações urbanas, ciência de dados, inventário de inundações.

INTRODUÇÃO

Precipitações extremas têm causado grande impacto em diversas regiões do mundo e a sua frequência e magnitude tem aumentado em diversas regiões em decorrência das alterações climáticas causadas pelo aquecimento global antropogênico e aumento de população vivendo em áreas expostas (Rogers et al., 2025). Áreas urbanas são particularmente vulneráveis a inundações com diferentes mecanismos de geração, incluindo inundações fluviais e pluviais sendo geradas, respectivamente, pelo extravasamento do nível de água dos rios para além de sua calha de inundaçao e pela ocorrência de precipitação para além da capacidade do sistema de drenagem e do solo de absorver água (Douben, 2006).

O mapeamento de suscetibilidade a inundações é uma etapa fundamental para gestão de risco de desastres tendo em vista o aumento da frequência e magnitude de eventos hidrológicos extremos. Neste caso, modelos hidrodinâmicos ganham bastante relevância para mapeamento de manchas de inundaçao. Esses modelos resolvem as equações de águas rasas em duas dimensões considerando as equações completas de Saint Venant, como é o caso do HEC-RAS, e a equação da onda difusiva que é uma simplificação dos termos iniciais das equações completas, muito útil para regiões declivosas, como é o caso do CAFLOOD (Buarque et al., 2021; Batalini de Macedo et al., 2024) e do HidroPol2D (Gomes Jr et al, 2023). Apesar de proverem grande precisão, em razão da demanda de dados de alta resolução e algoritmos com alto custo computacional, esses modelos geralmente são aplicados em pequenas áreas, apresentando uma dificuldade em escalar análise de risco de inundações urbanas em grandes áreas.

Com o aumento da coleta de dados sobre a ocorrência de inundações, novas abordagens baseadas em dados (data-driven) têm ganhado destaque, trazendo vantagens como maior capacidade de generalização dos modelos e aplicação em diferentes contextos espaciais (Guo et al., 2022). Entre essas abordagens, é comum o uso de modelos de classificação binária, nos quais pontos são rotulados como **positivos (1)** quando houve ocorrência de inundaçao, e **negativos (0)** quando não houve. No entanto, inventários de inundações geralmente registram apenas os locais onde a inundaçao ocorreu, não incluindo explicitamente os pontos onde não houve inundaçao. Ou seja, não há, nesses inventários, uma base de dados negativa confirmada. Isso representa um desafio importante para a modelagem de suscetibilidade à inundaçao, pois, para treinar modelos de classificação binária de forma adequada, idealmente precisaríamos saber tanto onde ocorreu quanto onde não ocorreu inundaçao durante os eventos analisados.

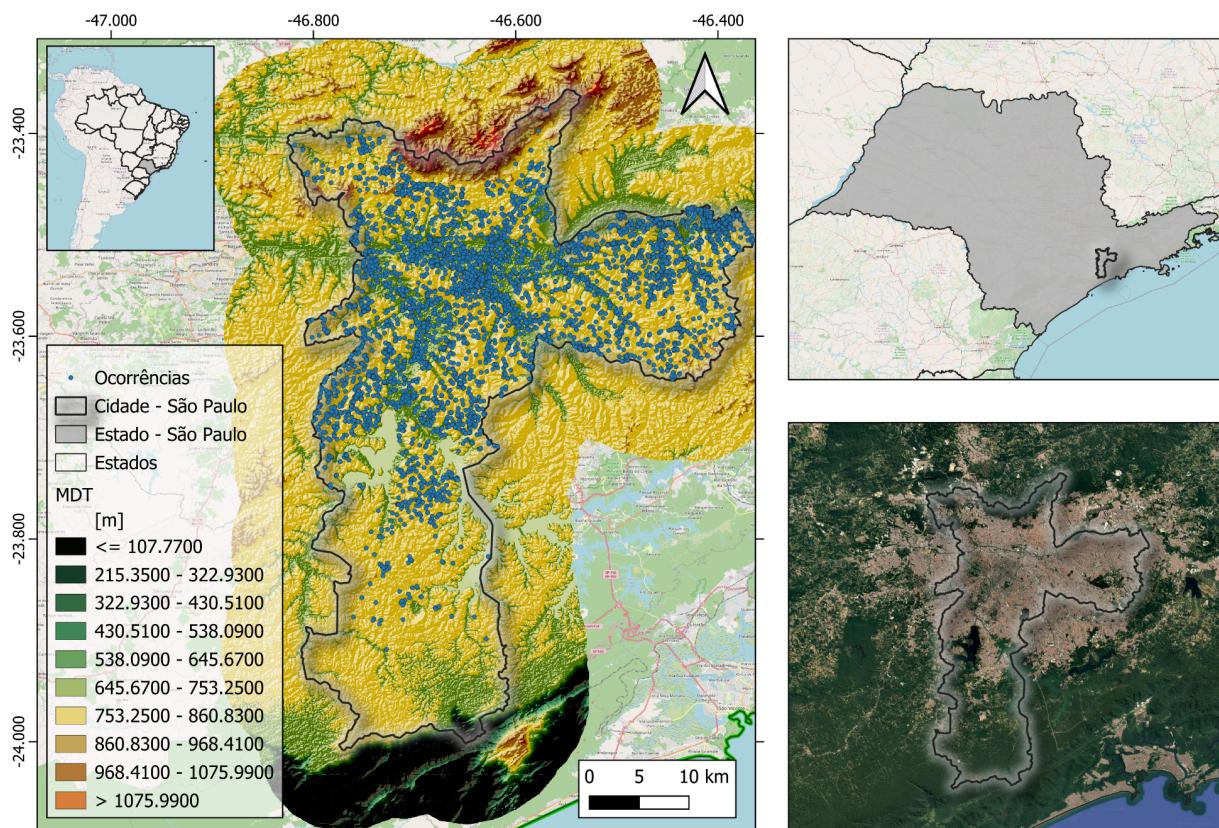
Para contornar esse problema, este trabalho propõe a utilização de uma abordagem de aprendizado de máquina com dados positivos e não rotulados (Positive and Unlabeled Learning – PU Learning). Essa metodologia permite treinar modelos a partir de dados em que apenas parte das ocorrências (positivas) são conhecidas com certeza, tratando os demais pontos da área como não rotulados em vez de negativamente confirmados, respeitando assim a incerteza associada à ausência de registros de inundaçao. A cidade de São Paulo é utilizada como referência para um estudo de caso aplicando a metodologia abordada neste estudo.

METODOLOGIA

ÁREA DE ESTUDO

O presente estudo foi conduzido na região metropolitana de São Paulo (Figura 1). O clima da região é classificado como subtropical úmido e com temperatura média anual de 19°C, de acordo com a classificação de Köppen. A região recebe anualmente cerca de 1400 mm de chuva, sendo que os maiores volumes precipitados ocorrem entre dezembro e fevereiro. Os meses de verão, particularmente janeiro, são os mais chuvosos, enquanto os meses de inverno recebem significativamente menores volumes de precipitação. Dadas as características da região, há um histórico de grande frequência de inundações, que são registradas por agentes da guarda e defesa civil local, desde 2013. Os registros de ocorrência contam com a localização do ponto em que foi identificado alagamento ou inundação e a data em que houve o registro. Os dados estão disponíveis para consulta no portal GeoSampa (s.d.). Ressalta-se que, para o desenvolvimento do presente estudo, os dados de ocorrência de alagamento e inundação foram considerados como uma categoria única, aqui referida apenas como inundação. Tal simplificação foi adotada devido à verificação de que a classificação não era realizada adequadamente pelos agentes que realizaram os registros, de modo a serem verificadas, por exemplo, inundações em locais distantes da rede de macrodrenagem.

Figura 1 - Informações detalhadas da área de estudo com localização dos pontos de ocorrência de inundações e alagamentos agregados



FATORES CONDICIONANTES DE INUNDAÇÕES URBANAS

Baseado na disponibilidade de dados do ANADEM na área de estudo, foram calculados diversos índices resultantes da elevação como fatores condicionantes de inundação urbana. Preliminarmente, foram selecionados os seguintes fatores condicionantes (Tabela 1): elevação, ângulo de declividade, aspecto, índice de rugosidade do terreno (TRI), índice de posição topográfica (TPI) com janelas, expressas em pixels, de 3 x 3, 8 x 8, 15 x 15, 25 x 25 e 35 x 35 - abrangendo desde uma análise local na vizinhança imediata (3 x 3) até uma escala muito ampla que capta macroformas de relevo (35 x 35), rugosidade, direção de fluxo (FLD), e altura acima da drenagem mais próxima. Os índices foram calculados em ambiente R com o uso do pacote terra (Hijmans, 2024). Os valores de HAND foram calculados usando o pacote whitebox (Wu & Brown, 2022). Os índices são baseados nas metodologias clássicas de análises geográficas com base em dados de DEMs (Jones, 1998; Karney, 2013).

Tabela 1 - Informações detalhadas dos fatores condicionantes de inundações urbanas

Fator condicionante	Descrição	Valores	Tipo de dado
Elevação (m)	Elevação em relação ao nível médio do mar	106.8-1176.5	Contínuo
Ângulo da declividade (°)	Declividade do terreno medida em graus	0.0-58.8	Contínuo
Aspecto (°)	Direção da bússola ou azimute que uma superfície do terreno enfrenta	0.0-360.0	Contínuo
TRI (°)	Índice de rugosidade do terreno	0.0-36.8	Contínuo
TPI (°)	Índice de posição topográfica janela em pixels de 8 x 8 (Queen case)	-17.2-17.9	Contínuo
TPI 3 (°)	Índice de posição topográfica janela em pixels de 3 x 3	-24.4-20.3	Contínuo
TPI 15 (°)	Índice de posição topográfica janela em pixels de 15 x 15	-79.7-70.8	Contínuo
TPI 25 (°)	Índice de posição topográfica janela em pixels de 25 x 25	-127.7-120.6	Contínuo
TPI 35 (°)	Índice de posição topográfica janela em pixels de 35 x 35	-158.8-156.0	Contínuo
Rugosidade (°)	Rugosidade medida em graus	0.0-106.2	Contínuo
FLD	Direção de fluxo	0-128	Discreto
HAND (m)	Altura acima da drenagem mais próxima	0-235	Contínuo

MODELO DE APRENDIZAGEM DE MÁQUINA (AM)

O fluxograma metodológico do presente estudo está apresentado na Figura 3. A metodologia é dividida em duas fases principais. A primeira fase diz respeito ao processo necessário para estimar os pontos negativos com base em dados não rotulados e a segunda fase consiste em treinar modelos de classificação para a geração de mapas de suscetibilidade a inundações.

Com base no trabalho seminal de Elkan e Noto (2008), descrevemos a base conceitual e matemática para a construção do modelo de classificação binária com dados positivos e não rotulados realizada neste trabalho. Considerando a Eq. 1, temos um conjunto de dados composto pela variável resposta binária y , que assume valor igual a um ($y = 1$) para pontos com ocorrência de inundação, e valor igual a zero ($y = 0$) para os demais casos. O objetivo é estimar a probabilidade de um ponto ser suscetível a inundações. O conjunto de dados é representado por (x, y) , em que x é uma matriz de covariáveis. Supõe-se ainda a existência de um subconjunto não observado s , que indica os dados que foram efetivamente rotulados como positivos (inundação) ou

negativos (sem inundação). No contexto desta pesquisa, busca-se estimar os casos negativos, ou seja, aqueles com ($s = 0$).

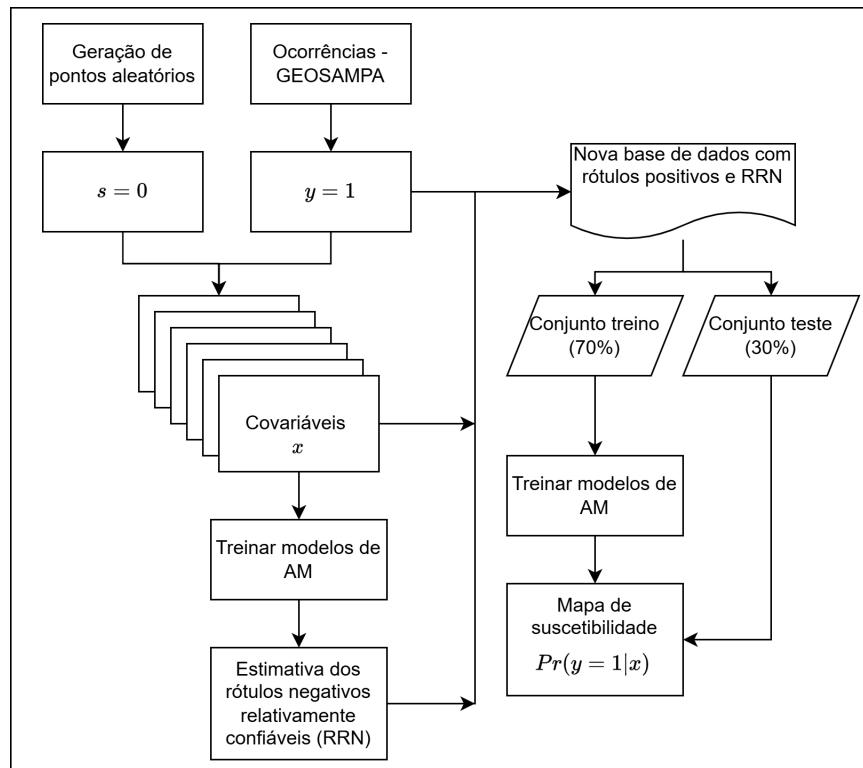
$$Pr(y = 1|x) \quad (1)$$

A estimativa dos pontos negativos é realizada por meio de um modelo do tipo Bayes Naïve que considera que a probabilidade à posteriori, isto é, a probabilidade dada pela Eq. 1, pode ser estimada com base nos valores positivos rotulados ($y = 1$), por meio da Eq. 2. Nesta equação, introduz-se um coeficiente c que se refere à probabilidade de um valor do conjunto s ser igual à 1.

$$Pr(s = 1|x) = \frac{Pr(y=1|x)}{Pr(y=1|x) + \frac{(1-c)}{c}} \quad (2)$$

A abordagem para treinar um modelo de classificação binária com base em dados positivos e não rotulados foi dividida em duas etapas conforme sugerido por Fu et al. (2024). A primeira etapa consiste em criar um modelo de aprendizagem de máquina para estimar um conjunto de dados negativos relativamente confiável (RRN do inglês *relatively reliable negatives*). A segunda etapa consiste em treinar modelos de aprendizagem de máquina de classificação binária com os dados considerando os dados positivos e negativos relativamente confiáveis.

Figura 3 –Fluxograma metodológico do estudo



A primeira etapa corresponde à uma solução da equação 2 com base nas covariáveis aqui representadas pelo conjunto de valores da Tabela 1. Para a estimativa de RNN, $Pr(y = 1|x)$ foi

estimado considerando diferentes modelos de machine learning implementados com o pacote *caret* (Kuhn, 2022) em ambiente R (R Core Team, 2024). Foram selecionados modelos baseados em comitê de aprendizagem. Random Forest (rf), eXtreme Gradient Boosting with tree booster (xgbTree) e eXtreme Gradient Boosting with linear booster (xgbLinear). Para a criação de uma base de dados inicial, considerou-se os pontos de inundação registrados na base de dados como $y = 1$ ($n = 11181$) e foi gerada uma nuvem de pontos aleatórias considerando a área da cidade de São Paulo para $y = 0$ ($n = 2981$ que corresponde a 25% da quantidade de pontos positivos).

Para se obter estimativas confiáveis de RRN é necessária uma rigorosa rotina de calibração dos modelos de aprendizagem de máquina. O processo de calibração é frequentemente nomeado de ajuste de hiperparâmetros. A diferença primordial entre um parâmetro e um hiperparâmetro é que o primeiro é um conjunto a ser produzido pelo algoritmo de AM e o último se refere a um conjunto que controla o processo de aprendizagem. Os três algoritmos de AM utilizados foram ajustados com validação cruzada com 10 dobras (10-fold) e três repetições. O ajuste foi feito por busca aleatória com 10 repetições, isto é, o processo de validação cruzada foi repetido 10 vezes para garantir maior confiabilidade do ajuste. Ao final, as médias dos quatro modelos são utilizadas para estimar as probabilidades de um dado ponto ser positivo, caso a probabilidade for baixa, considera-se, então que o dado ponto é um RRN.

O valor de c é estimado com base nos valores estimados com o modelo de machine learning com dados não rotulados cuja estimativa de rótulo positivo ($s = 1|x$) é igual ao rótulo positivo observado ($y = 1$). O valor de c reflete a probabilidade da predição ser positiva quando o valor observado de fato é positivo conforme a Equação 3. Por fim, os valores de RRN são aqueles cuja probabilidade de serem positivos é menor que um limiar. Aqui, o limiar adotado é menor que 0.05, isto é, $P(x) < 0.05$.

$$g(x) = Pr(y = 1|x, y = 1) = c \quad (3)$$

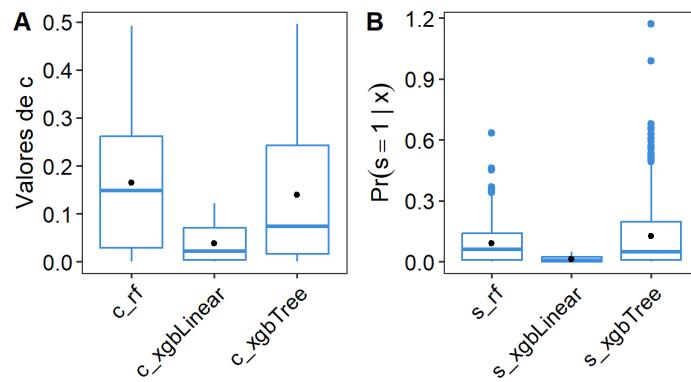
A segunda etapa consiste em considerar o novo conjunto formado por observações de pontos de inundações e estimativas de pontos de não inundação para treinar novos modelos de AM. Os modelos passaram por uma nova rodada de treino e teste com calibração por validação cruzada com 10 dobras e 3 repetições cujo processo é realizado 10 vezes. Para esta etapa, reservou-se 75% do conjunto de dados para treino e 25% para teste. Essa separação foi criada por partição aleatória considerando a manutenção da mesma proporção das classes inundação e não inundação em ambos os conjuntos. Duas métricas de performance foram adotadas para avaliar os modelos, a acurácia e o kappa. Mais informações sobre como as métricas são calculadas podem ser encontradas em Vujović (2021). Para avaliação do mapa de suscetibilidade, também foi considerada uma mancha de inundação gerada pelo modelo hidráulico da onda difusiva CADDIES/CAFLOOD feito para um evento na bacia do Rio Aricanduva por Benso et al. (2024).

RESULTADOS E DISCUSSÃO

Neste estudo, duas etapas de modelagem com algoritmos de aprendizagem de máquina foram conduzidas. A primeira, está vinculada a necessidade de estimar pontos com rótulos negativos relativamente confiáveis (RRN). O resultado das estimativas de valores da constante c que indica a probabilidade de um ponto ser rotulado como positivo, conforme a Equação 3, e valores de probabilidade de um valor não rotulado ser positivo, conforme a Equação 2, estão

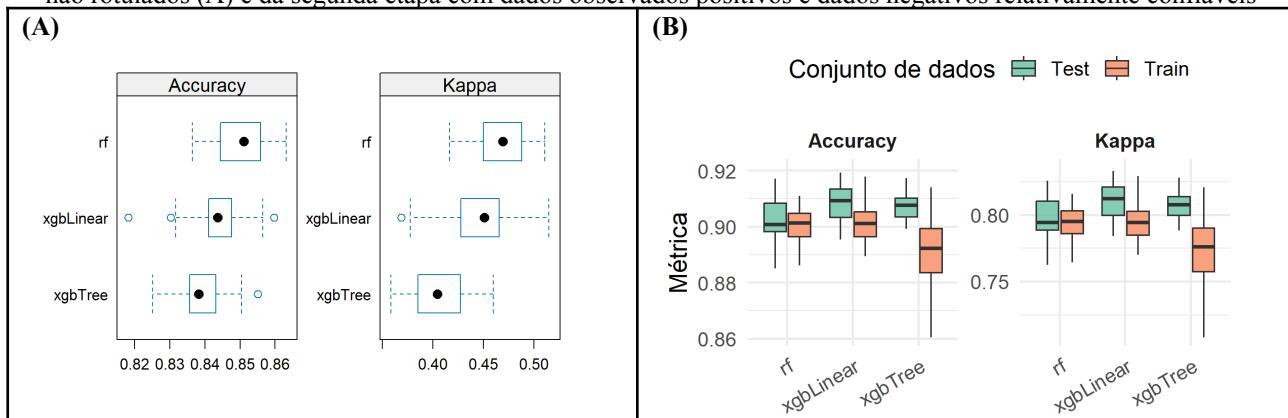
descritos na Figura 4. Os valores não rotulados são um conjunto de pontos espaciais cujo rótulo é desconhecido, desta forma, o método classifica quais dos pontos são provavelmente negativos.

Figura 4 – Resultados das estimativas de c e $P(x) < 0.05$



A primeira etapa de modelagem promove a criação de uma nova base de dados composta por dados de ocorrência de inundações que são observados e dados rotulados negativos relativamente confiáveis (RRN) que foram classificados. Na Figura 5-A estão demonstradas as métricas de performance do modelo da primeira etapa. Conforme a Figura 5-B, os valores de Kappa superiores a 0,8 indicam modelos com nível de concordância forte e faixa de confiabilidade maior que 64% (McHugh, 2012). Analisando as métricas, observa-se que a metodologia empregada neste estudo significativamente melhora a habilidade do modelo em classificar pontos de inundação. Na fase um do modelo (Figura 5-A), as métricas de performance variam entre 0,4 e 0,45 (mediana) e aumentam para cerca de 0,77 a 0,82 (mediana) na fase dois. Considerando as métricas de performance tanto no treino quanto no teste, o modelo xgbLinear é escolhido como o melhor modelo para prever suscetibilidade a inundações neste estudo de caso. O xgbLinear também demonstrou menor overfitting, com diferenças reduzidas entre os desempenhos no conjunto de treino e teste, o que reforça sua capacidade de generalização para novos dados.

Figura 5 – Resultados do modelo da primeira etapa de modelagem com dados observados com rótulo positivo e dados não rotulados (A) e da segunda etapa com dados observados positivos e dados negativos relativamente confiáveis

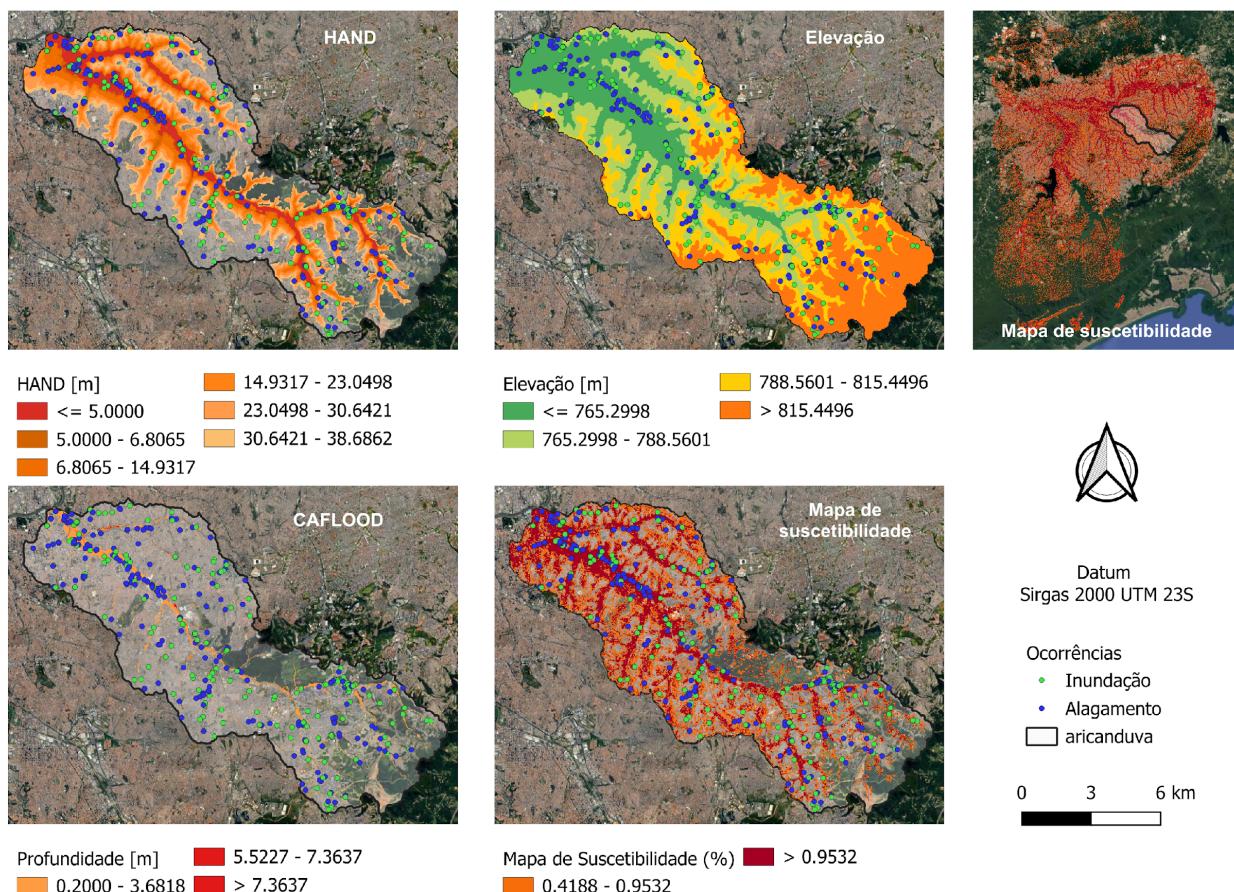


A combinação dos resultados da segunda etapa de modelagem está ilustrada na Figura 6. Para fins ilustrativos, foram selecionadas duas faixas de suscetibilidade geradas pelo modelo xgbLinear: entre 0,4188 e 0,9532, e acima de 0,9532. Esses intervalos foram aplicados à bacia do

Aricanduva, situada na zona leste do município de São Paulo, onde as ocorrências observadas de inundação e alagamento também estão destacadas nos mapas.

Como forma de comparação, são apresentadas na figura camadas adicionais relevantes para a dinâmica de inundação: o índice HAND, o modelo digital de elevação (MDE), e os resultados da simulação hidrodinâmica para um evento específico por meio do modelo CAFLOOD 2D feito por Benso et al. (2024). A comparação visual dessas camadas com a suscetibilidade modelada revela correlação espacial elevada entre áreas de maior suscetibilidade e regiões com menor HAND e altitudes mais baixas — o que é esperado, considerando que ambas as variáveis foram utilizadas como covariáveis no treinamento do modelo de aprendizado de máquina. Por outro lado, a sobreposição com os resultados do CAFLOOD mostra um padrão mais pontual e concentrado, refletindo a resposta hidrodinâmica simulada para um evento específico. Ainda assim, as áreas de maior suscetibilidade estimadas pelo modelo de aprendizado de máquina apresentam coerência espacial com as áreas efetivamente inundadas, conforme identificado nas simulações.

Figura 6 – Comparação espacial entre diferentes camadas de análise de suscetibilidade à inundação na bacia do Aricanduva, zona leste do município de São Paulo



CONCLUSÕES

O presente trabalho apresentou um estudo de mapeamento de suscetibilidade a inundações por meio do uso de dados de ocorrência de inundação na cidade de São Paulo, SP. Como base

metodológica para treinar um algoritmo de classificação binária, utilizou-se o método de classificação com dados positivos e não rotulados.

Foram testados três modelos de aprendizado de máquina (AM) - xgbTree, xgbLinear e RandomForest -, sendo que a análise de performance, incluindo treino e teste, apresentou valores de kappa superiores a 0,80 e acurácia superior a 0,90, indicando forte confiabilidade do método. Comparando as métricas dos três modelos, concluiu-se que o modelo xgbLinear apresentou performance superior aos demais, tanto na fase de treino quanto na fase de teste.

O mapa de suscetibilidade foi comparado com a mancha de inundação gerada por simulações hidrodinâmicas utilizando o modelo CADDIES/CAFLOOD, que resolve as equações da onda difusiva em duas dimensões. A sobreposição com diferentes pontos de ocorrência de inundação observada evidencia a capacidade do modelo de aprendizado de máquina em generalizar padrões espaciais de suscetibilidade, extrapolando além dos pontos positivos originalmente disponíveis no inventário.

Trabalhos futuros devem explorar o uso de outras informações que possam refletir mudanças climáticas, como precipitação associada a cada evento. Com isso, seria possível introduzir diferentes mapas de suscetibilidade conforme o tempo de retorno de eventos extremos. Além disso, deve-se levar em consideração outras informações, como dados sobre infraestrutura de drenagem, uso e ocupação do solo e dados de satélite, para aprimorar os mapas gerados por modelos de aprendizagem de máquina.

REFERÊNCIAS

- BATALINI DE MACEDO, M., MANGUKIYA, N. K., FAVA, M. C., SHARMA, A., FRAY DA SILVA, R., AGARWAL, A., RAZZOLINI, M. T., MENDIONDO, E. M., GOEL, N. K., KURIAN, M., AND NARDOCCI, A. C.: “*Performance analysis of physically-based (HEC-RAS, CADDIES) and AI-based (LSTM) flood models for two case studies*”. Proc. IAHS, 386, 41–46, <https://doi.org/10.5194/piahs-386-41-2024>, 2024.
- BENSO, M. R., MACEDO, M. B. DE, LOPES, A. V., VASCONCELOS, A. F., CARVALHO, B. C. S. DE, COSTA, M. E. L., TOMASELLA, J., FAVA, M. C., & BISCARO, T. S. (2024). “*Efeito da resolução de modelos digitais de elevação na acurácia de modelagem hidráulica em áreas urbanas*”. Anais do XV ENAU – Encontro Nacional de Águas Urbanas e V SRRU – Simpósio de Revitalização de Rios Urbanos, Recife, PE, Brasil. Associação Brasileira de Recursos Hídricos. <https://www.abrhidro.org.br/xvenau>
- BUARQUE, A. C. S., SOUZA, C. F., SOUZA, F. A. A., & MENDIONDO, E. M. (2021). “*Urban flood risk under global changes: a socio-hydrological and cellular automata approach in a Brazilian catchment*”. Hydrological Sciences Journal, 66(14), 2011-2021.
- ELKAN, C., & NOTO, K. (2008). “*Learning classifiers from only positive and unlabeled data*”. In Proceedings of the 14th ACM SIGKDD international conference on Knowledge discovery and data mining (pp. 213-220).
- FU, Z., MA, H., WANG, F., DOU, J., ZHANG, B., & FANG, Z. (2024). “*An Integrated Framework of Positive-unlabeled and Imbalanced learning for Landslide Susceptibility Mapping*”. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing.
- DOUBEN, K. J. (2006). “*Characteristics of river floods and flooding: a global overview*”, 1985–2003. Irrigation and Drainage: The journal of the International Commission on Irrigation and Drainage, 55(S1), S9-S21.

- GEOSAMPA (s.d.). “*Mapa digital da Cidade de São Paulo*”. Geosampa.prefeitura.sp.gov.br. https://geosampa.prefeitura.sp.gov.br/PaginasPublicas/_SBC.aspx
- GUO, Z., MOOSAVI, V., & LEITÃO, J. P. (2022). “*Data-driven rapid flood prediction mapping with catchment generalizability*”. Journal of Hydrology, 609, 127726.
- HIJMANS R (2024). “*terra: Spatial Data Analysis*”. R package version 1.7-71, <https://CRAN.R-project.org/package=terra>.
- JONES, K.H., (1998). “*A comparison of algorithms used to compute hill slope as a property of the DEM*”. Computers & Geosciences 24: 315-323
- KARNEY, C.F.F., (2013). “*Algorithms for geodesics*”. J. Geodesy 87: 43-55. doi:10.1007/s00190-012-0578-z.
- KUHN, MAX (2022). “*caret: Classification and Regression Training*”. R package version 6.0-93. <https://CRAN.R-project.org/package=caret>.
- GOMES JR, M. N., DO LAGO, C. A. F., RÁPALO, L. M. C., OLIVEIRA, P. T. S., GIACOMONI, M. H., & MENDIONDO, E. M. (2023). “*HydroPol2D—Distributed hydrodynamic and water quality model: Challenges and opportunities in poorly-gauged catchments*”. Journal of Hydrology, 625, 129982.
- MCHUGH, M. L. (2012). “*Interrater reliability: the kappa statistic*”. Biochimia medica, 22(3), 276-282.
- R Core Team (2024). “*R: A Language and Environment for Statistical Computing*”. R Foundation for Statistical Computing, Vienna, Austria.
- ROGERS, J. S., MANETA, M. M., SAIN, S. R., MADAUS, L. E., & HACKER, J. P. (2025). “*The role of climate and population change in global flood exposure and vulnerability*”. Nature Communications, 16(1), 1287.
- VUJOVIĆ, Ž. (2021). “*Classification model evaluation metrics*”. International Journal of Advanced Computer Science and Applications, 12(6), 599-606.
- WU, Q., BROWN, A. (2022). “*whitebox: 'WhiteboxTools' R Frontend*”. R package version 2.2.0. <<https://CRAN.R-project.org/package=whitebox>>

AGRADECIMENTOS - Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa concedida ao primeiro autor (processo 381989/2024-0) e financiamento pela Chamada CNPq/MCTI Nº 15/2023 – Eventos Meteorológicos Extremos: Prevenção de Desastres Naturais e Minimização de Danos (processo 446029/2023-8).