

XXV SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS

ANÁLISE COMPARATIVA DE MODELOS DE APRENDIZADO DE MÁQUINA PARA MAPEAMENTO DE INUNDAÇÕES

Vinicius Kuchinski¹; Rodrigo Cauduro Dias de Paiva²

Abstract: This study presents a comparative analysis of various machine learning models for the estimation of flood events. The examined models include AdaBoost, Decision Tree, Gaussian Naïve Bayes, Gradient Boosting, K-Nearest Neighbors, Linear Discriminant Analysis, Quadratic Discriminant Analysis, Random Forest, and Support Vector Machine. These models were trained on a dataset consisting of twelve independent variables, primarily derived from remote sensing data. To compare the performance of the selected models and evaluate their capability, evaluation metrics such as accuracy, Jaccard index, precision, recall, F1 score, and area under the ROC curve were utilized. The results indicated that Random Forest, Gradient Boosting, and K-Nearest Neighbors achieved the highest scores in the metrics, with Random Forest exhibiting superior performance compared to the others. Additionally, the top-performing models were assessed for estimating two extreme events, extrapolating beyond the training data characteristics, and the metric results indicated the models' inability to extrapolate. This work highlights the effectiveness of machine learning models in mapping flood inundation when the flood represents an event of magnitude previously known to the classifiers.

Resumo: Esse estudo apresenta uma análise comparativa de diversos modelos de aprendizado de máquina para o mapeamento de inundações. Os modelos examinados neste estudo são *AdaBoost*, *Decision Tree*, *Gaussian Naïve Bayes*, *Gradient Boosting*, *K-Nearest Neighbors*, *Linear Discriminant Analysis*, *Quadratic Discriminant Analysis*, *Random Forest*, e *Support Vector Machine*. Os modelos foram treinados com um conjunto de doze variáveis independentes, principalmente provenientes de dados de sensoriamento remoto. Para comparar o desempenho e avaliar a capacidade preditiva dos modelos selecionados, foram utilizadas as seguintes métricas de avaliação: acurácia, índice de Jaccard, precisão, *recall*, *F1 score* e área sob a curva ROC. Os resultados demonstraram que *Random Forest*, *Gradient Boosting* e *K-Nearest Neighbors* obtiveram as maiores pontuações nas métricas avaliadas, sendo que o *Random Forest* apresentou um desempenho superior aos demais. Além disso, os dois melhores modelos foram testados realizando o mapeamento de dois eventos extremos, extrapolando-os para além das características de treinamento, os resultados das métricas indicaram a incapacidade de extrapolação dos modelos. Esse trabalho apresenta a eficácia dos modelos de aprendizado de máquina para representar inundações e fazer estimativas, desde que essas inundações sejam de eventos de magnitude previamente conhecidas pelos classificadores.

Palavras-Chave – mapeamento de inundação; inteligência artificial; modelagem.

1) Afiliação: Pós-graduando no Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 91501-970, Brasil, eng.vinicius@outlook.com

2) Afiliação: Professor no Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 91501-970, Brasil, rodrigo.paiva@ufrgs.br

INTRODUÇÃO E OBJETIVO

Inundações são desastres naturais que podem ser devastadores, ocasionando danos potenciais. O centro de pesquisa em epidemiologia de desastres mantém um banco de dados atualizado de informações sobre desastres no mundo todo, e esse registro mostra que até 2020, cerca de 34% dos desastres naturais são causados por inundações (EM-DAT, 2020) e, no Brasil, cerca de 18% dos decretos de calamidade pública ou de emergência emitidos são referentes a esses fenômenos (CNM, 2022).

A previsão e o mapeamento de inundações podem ser realizados por modelos físicos, de processos físicos ou empíricos (MUDASHIRU *et al.*, 2021). Modelos de aprendizagem supervisionada são modelos de aprendizagem de máquina considerados empíricos, em que o algoritmo reconhece relações entre os dados de entrada e as saídas já conhecidas na etapa de treinamento, podendo ser utilizado para classificações posteriores. Esses algoritmos de classificação já são utilizados para mapeamento de inundações (e.g.: CHEN *et al.*, 2020; LI *et al.*, 2019; LIU *et al.*, 2017; MAILLARD *et al.*, 2022; TIAMPO *et al.*, 2022; WANG *et al.*, 2021).

A aprendizagem supervisionada tem se destacado como uma abordagem promissora para lidar com a crescente disponibilidade de dados provenientes de diversas fontes, como o sensoriamento remoto. Nesse contexto, a disseminação do uso de linguagens de programação, aliada a iniciativas como o *Google Earth Engine* e o *Colab*, tem facilitado o acesso e o processamento desses dados em larga escala. Os algoritmos de classificação apresentam-se como ferramentas viáveis para aproveitar a quantidade de informações disponíveis e explorar a capacidade de processamento disponíveis no mercado. Esses algoritmos permitem a identificação de padrões e relações complexas nos dados (RASCHKA *et al.*, 2022), possibilitando a criação de modelos preditivos e auxiliando a tomada de decisões embasadas em informações precisas.

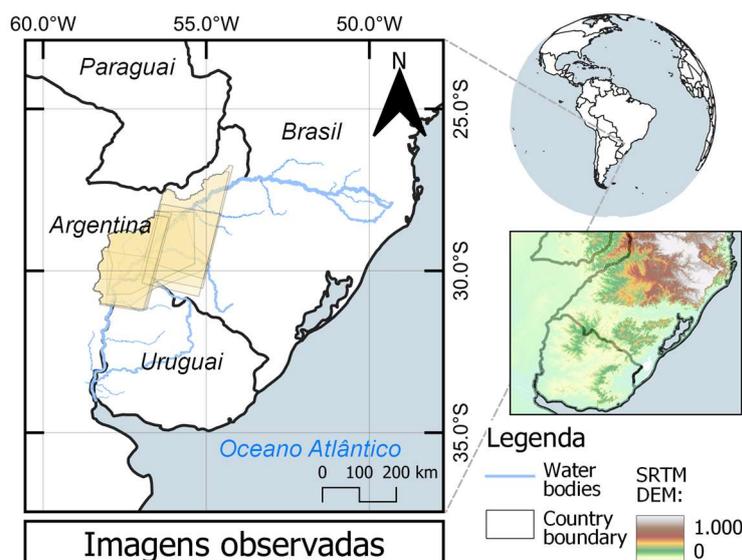
Nesse sentido, o objetivo desse trabalho é de fazer uma comparação de modelos de aprendizado supervisionado para a estimativa de manchas de inundação, através de uma análise conjunta de múltiplos eventos de inundação de diferentes magnitudes. Pretende-se, por meio da análise de diferentes métricas de desempenho, identificar os modelos classificadores que apresentem os resultados mais acurados, e os testar para estimativas das manchas de inundação de eventos extremos, com o maior e o menor tempo de retorno (TR) associados, verificar sua usabilidade e capacidade de extrapolação para outras condições diferentes daquelas utilizadas no seu treinamento.

METODOLOGIA

Área de estudo

A área de estudo definida para este trabalho é o rio Uruguai, mostrado na figura 1, que é um importante rio que define os limites territoriais de três países: Argentina, Brasil e Uruguai. O rio tem aproximadamente 2.200 km² de extensão, originando-se da confluência dos rios Pelotas e do Peixe, e desaguando no estuário do rio da Plata, na Argentina, cobrindo uma área de aproximadamente 105.000 km².

Figura 1 – Localização da área de estudo, identificando as imagens de satélite utilizadas, em amarelo.



Dados utilizados

Foram selecionados doze atributos espaciais, exemplificados na figura 2, que neste caso, são as variáveis independentes do modelo, baseados em estudos pretéritos (KAISER *et al.*, 2022). Os atributos foram selecionados por critérios de maior resolução temporal e abrangência de larga escala, continental ou global.

Os atributos utilizados são descritos a seguir, iniciando por aqueles que tem relação com a topografia da região, que são o modelo digital de superfície (DSM, Tadono *et al.*, 2014), a inclinação do terreno (SLOPE, NASA JPL, 2020) e a altura acima da rede de drenagem mais próxima (HAND, Yamazaki *et al.*, 2019). Também foram utilizados atributos com características relacionadas ao solo como a textura do solo para profundidades de 10 e 30 cm (SOIL10 e SOIL30, Hengl, 2018), respectivamente, além do uso e da ocupação do solo (LULC, Buchhorn *et al.*, 2020).

Além desses, foram utilizados atributos com relação com água no solo, como a frequência de ocorrência de água ao longo do tempo (FO, Pekel *et al.*, 2016) e o volume de água armazenado no solo para dois horizontes diferentes, o superficial e o subsuperficial (SSW e SUSW, Copernicus Climate Change Service, 2019). Por fim, atributos que possuem relação com a precipitação e vazão, como a precipitação acumulada para 7 e 30 dias antecedentes à data do evento, respectivamente (RF7 e RF30, Funk *et al.*, 2015) e o período de retorno da vazão atribuída ao trecho de rio naquela área, procedente do modelo hidrológico e hidrodinâmico denominado Modelo de Grandes Bacias (MGB) (QPR, Siqueira *et al.*, 2018).

Como dados observados, ou seja, variável dependente para treinamento e teste do modelo, foram utilizadas manchas de inundação extraídas de imagens de satélite de eventos de inundação, listadas na tabela 1 e representados na figura 1. As manchas foram obtidas por Alves *et al.*, (2021), por índice de diferença normalizada da água (NDWI), proposto por McFeeters (1996), com exceção da imagem Sentinel 1 *Synthetic Aperture Radar* (SAR) que foi utilizado um algoritmo supervisionado de *Support Vector Machine*.

Figura 2 – Variáveis dependentes utilizadas para o treinamento dos modelos classificadores.

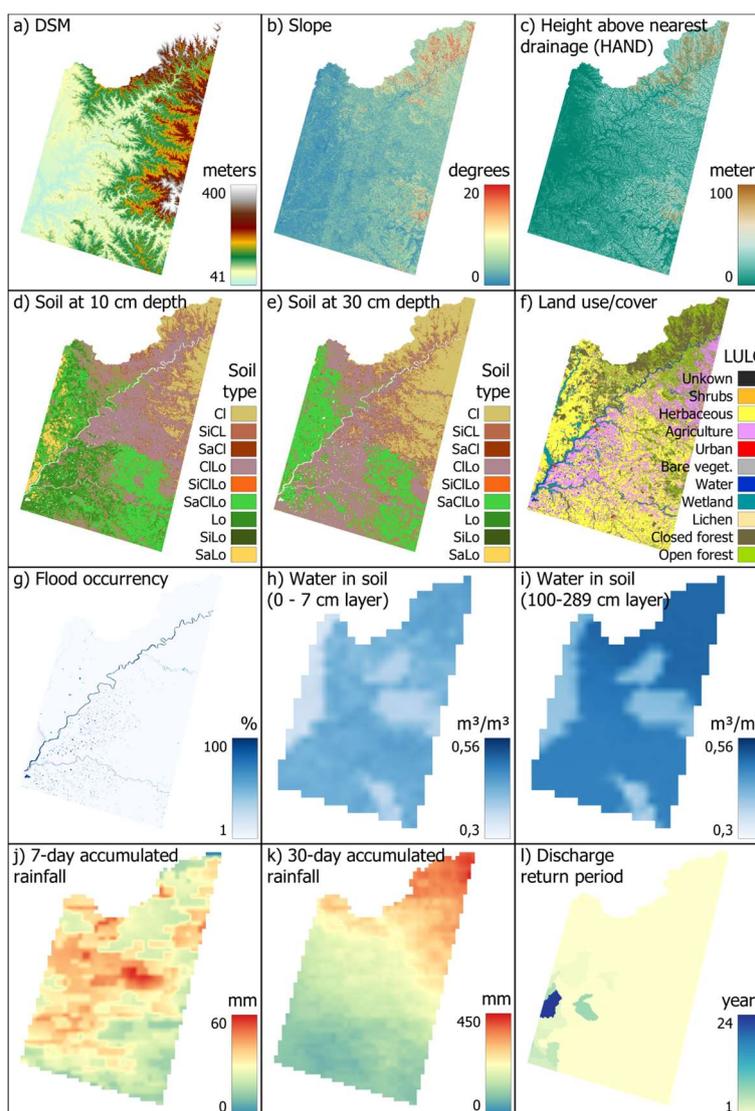


Tabela 1 – Data, fonte e maior tempo de retorno em anos das minibacias (e do trecho do rio principal) das imagens de satélite de eventos de inundação utilizados como dados observados.

Data	Fonte	TR de Q
08/06/1990	Landsat 5 Thematic Mapper (TM)	11 (08)
17/06/1990	Landsat 5 Thematic Mapper (TM)	24 (03)
26/10/1997	Landsat 5 Thematic Mapper (TM)	05 (02)
23/10/2002	Landsat 7 Enhanced Thematic Mapper Plus (ETM+)	22 (03)
05/12/2009	Landsat 5 Thematic Mapper (TM)	42 (09)
05/07/2014	Landsat 8 Operational Terra Imager e Thermal Infrared Sensor	15 (15)
02/06/2017	Sentinel 1 Synthetic Aperture Radar (SAR)	09 (02)
12/06/2017	CBERS4 Advanced Wide Field Imager (AWFI)	10 (06)
22/01/2019	CBERS4 Advanced Wide Field Imager (AWFI)	16 (02)

Pré-processamento

Essa etapa consistiu no preparo dos dados para posterior entrada no modelo. Assim, os dados foram reprojetoados para que todos estivessem com a mesma projeção UTM, com a mesma resolução e suas extensões compatibilizadas, sendo esses processos executados em software de geoprocessamento (QGIS).

Posteriormente, os dados foram transformados em uma matriz composta de 13 vetores de uma dimensão, sendo as doze variáveis independentes, além da variável dependente. Os dados faltantes, nas bordas das imagens ou recortados em função da bacia de drenagem, foram desconsiderados como dados de entrada do modelo, sendo que eventuais remanescentes foram substituídos pelo valor da mediana para aquela variável, e esse processo foi realizado através de algoritmo em linguagem Python. O treinamento e a validação dos modelos foram realizados por meio de amostragem nas imagens de referência (tabela 1), utilizando 100.000 dados amostrais, sendo 70% destes para treino e 30% para validação.

Modelos treinados

Os modelos utilizados neste trabalho são: *AdaBoost* (AB), *Decision Tree* (DT), *Gaussian Naive Bayes* (GNB), *GradientBoosting* (GB), *K-Nearest Neighbors* (KNN), *Linear Discriminant Analysis* (LDA), *Quadratic Discriminant Analysis* (QDA), *Random Forest* (RF) e *Support Vector Machine* (SVM), todos implementados por meio da biblioteca *scikit-learn* do Python (PEDREGOSA et al., 2011).

Esses modelos foram escolhidos pela facilidade de implementação através da biblioteca, visto que apenas os dados de entrada foram suficientes para sua implementação, utilizando a configuração padrão, através do aprendizado supervisionado.

Avaliação dos modelos

Os modelos foram avaliados por meio de métricas de desempenho. As métricas selecionadas foram: acurácia (*accuracy*), índice de Jaccard (também conhecido como *critical success index*), a precisão (*precision*), a sensibilidade (*recall*), a área sob a curva ROC (AUC) e o índice F1.

A *accuracy* é a proporção dos acertos pelo número total de dados (GHARAKHANLOU e PEREZ, 2023), o índice de Jaccard é uma métrica que penaliza os erros de excesso e escassez de previsão (BATES e DE ROO, 2000), sendo uma métrica adequada para previsões de extensão de inundações. *Precision* é proporção de verdadeiros positivos entre os casos classificados como positivos pelo modelo classificador (GHARAKHANLOU e PEREZ, 2023) e *recall* é a proporção de verdadeiros positivos que foram corretamente identificados pelo modelo classificador (CHANG et al., 2022). O índice F1 é a média harmônica entre *precision* e *recall* (CHANG et al., 2022). AUC o valor da área sob a curva ROC, que é um gráfico que tem como eixos as taxas de verdadeiros positivos e de falsos positivos (WANG et al., 2022). Para todas essas métricas, quanto maior seu valor, melhor é o desempenho do classificador na estimativa.

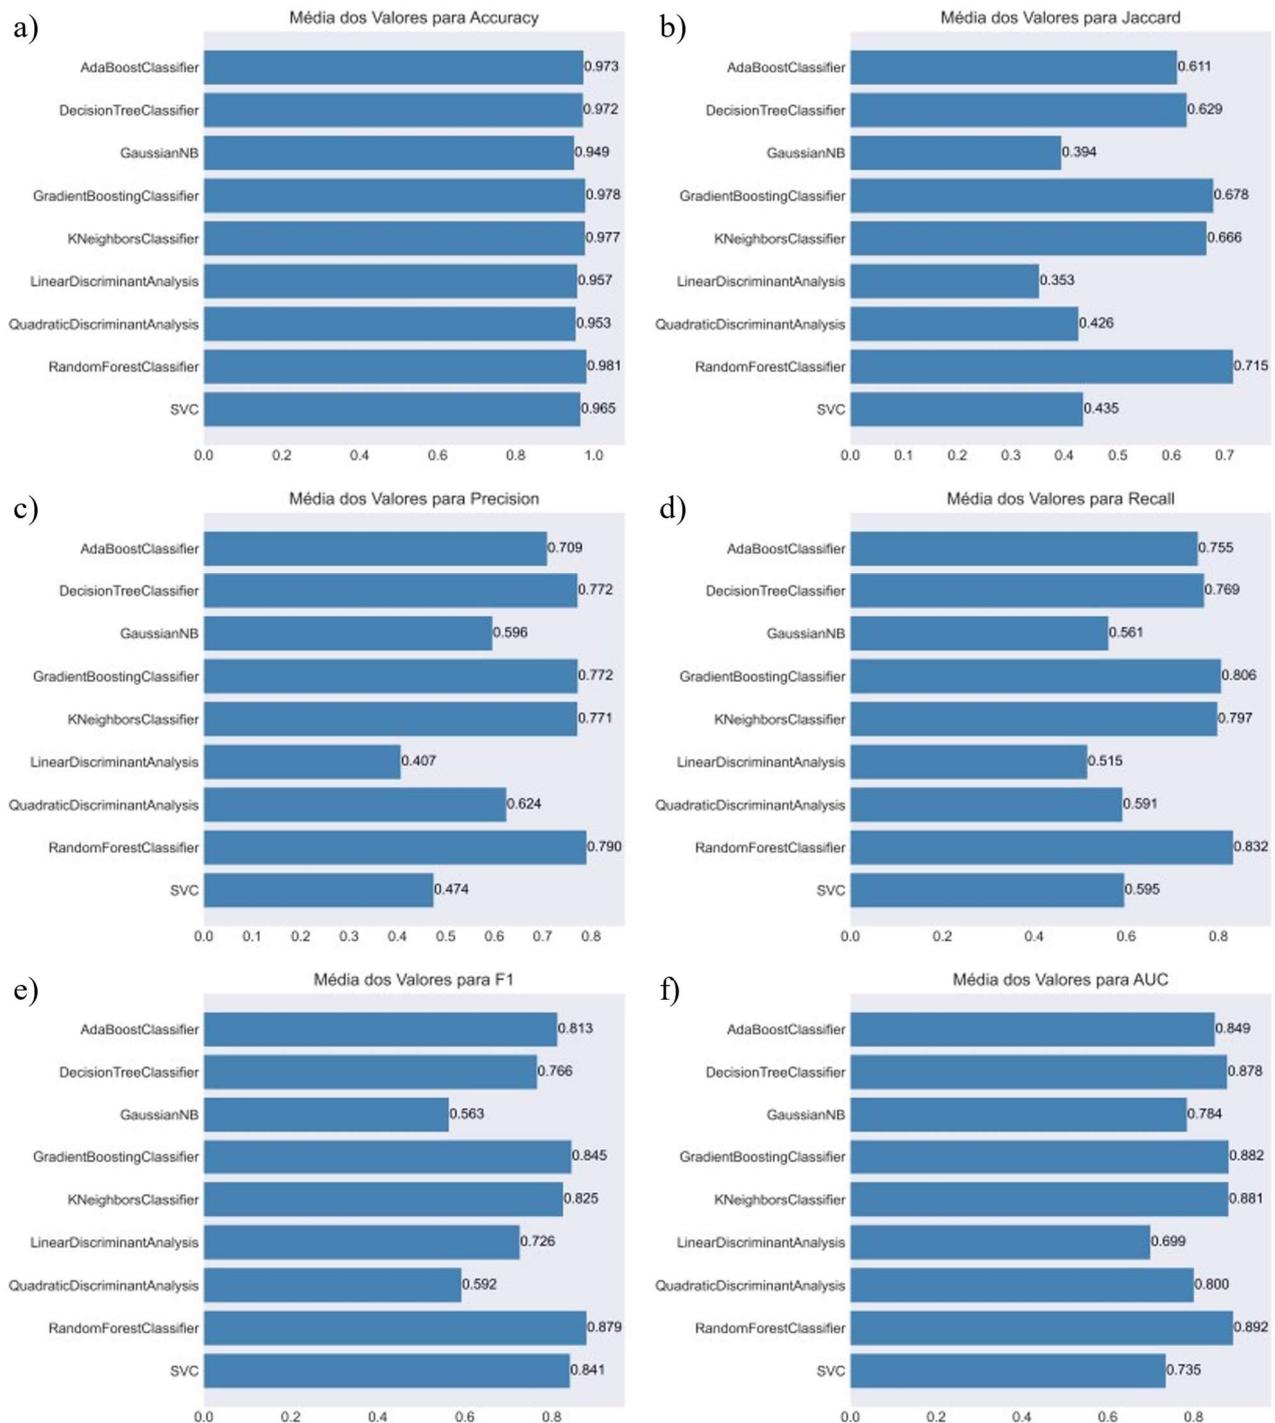
Teste de extrapolação

Para testar a capacidade de generalização dos modelos treinados, os dois melhores modelos foram selecionados para fazer o mapeamento de dois eventos extremos relacionados na tabela 1, que são os eventos ocorridos em 26/10/1997 e 05/12/2009.

RESULTADOS E DISCUSSÃO

Foram treinados nove modelos para cada um dos eventos de inundação, totalizando 81 modelos treinados. Para facilitar a compreensão do desempenho de cada um deles na estimativa de manchas de inundação, foi realizado o cálculo da média aritmética dos valores de cada uma das métricas, para cada tipo de modelo treinado. Os gráficos contendo os valores médios das métricas estão apresentados na figura 3.

Figura 3 – Valores médios das métricas de avaliação obtidos pelos modelos adotados.



Considerando a análise das métricas de desempenho dos modelos de classificação, podemos observar os seguintes resultados: em relação à acurácia (figura 3a), os três modelos com melhor desempenho foram RF com uma acurácia de 0,981, seguido por GB com 0,978, e KNN com 0,977. Para o índice de Jaccard, também conhecido como índice de sucesso crítico (figura 3b), o classificador com o melhor desempenho foi o RF com um valor de 0,715. Em seguida, temos o GB com 0,678 e o KNN com 0,666. Por fim, considerando a métrica de Área Sob a Curva (AUC) (figura 3f), os melhores classificadores foram RF, GB e KNN, com valores de 0,892, 0,892 e 0,881, respectivamente.

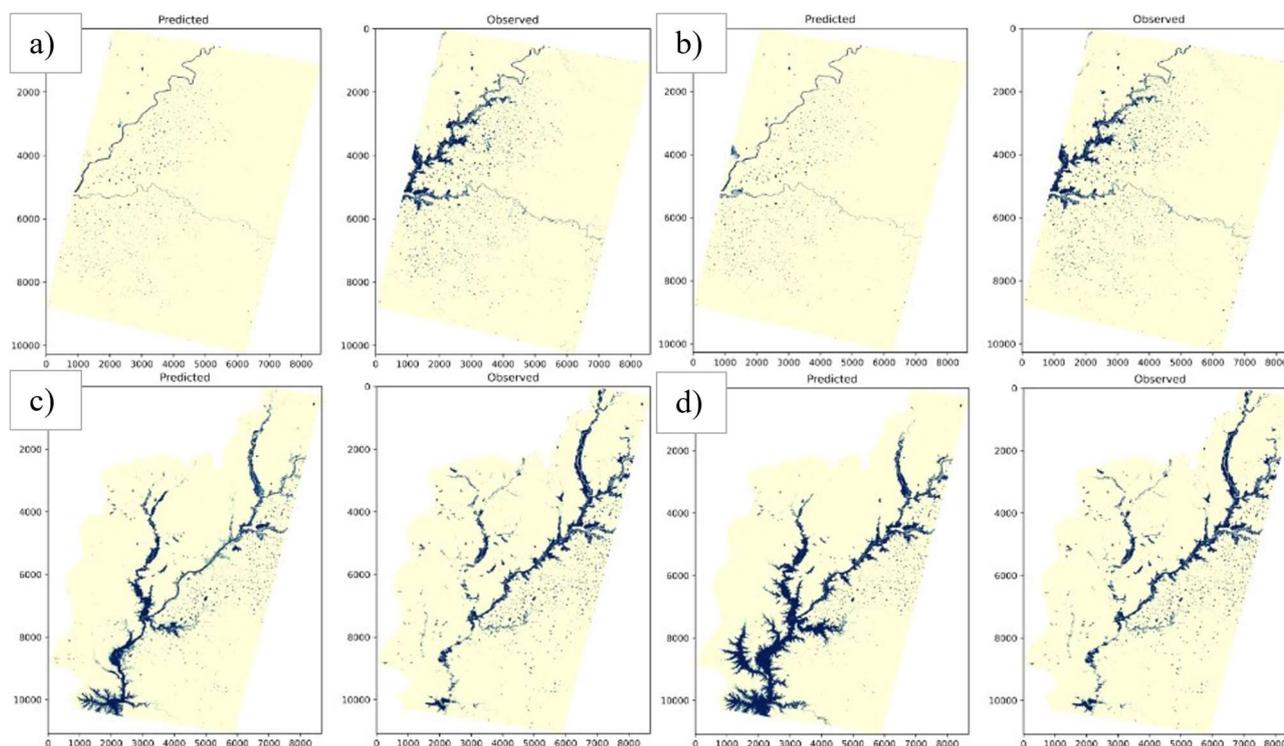
Ao analisar a métrica de Precisão (figura 3c), os três melhores classificadores foram RF com um valor de 0,790, seguido por GB e DT, ambos com valores em torno de 0,772. No que diz respeito à métrica de Recall (figura 3d), os melhores desempenhos foram observados nos classificadores RF com 0,832, GB com 0,806 e KNN com 0,797. Analisando a métrica F1 (figura 3e), que combina precisão e recall em uma única medida, o RF obteve o melhor desempenho com um valor de 0,879, seguido por GB com 0,845, e SVM com 0,841.

No teste de capacidade de extrapolação, foram selecionados os dois modelos com melhor desempenho nas métricas: RF e GB, ambos treinados para o evento de inundação de 08/06/1990. A comparação entre os dados observados e os dados previstos estão apresentados na figura 4. Fica visualmente claro que os modelos tiveram dificuldades para realizar as extrapolações, subestimando a área inundada para o evento com TR menor (4a e 4b) e superestimando a área inundada para o evento com TR maior (4c e 4d). Das métricas de avaliação, destacam-se negativamente: o índice Jaccard variando de no mínimo 0,25 a no máximo 0,43, e a precisão com valores de 0,26 e 0,33 para a data de 26/10/1997 (4a e 4b, respectivamente).

Esses resultados indicam que o RF obteve o melhor desempenho em diversas métricas de avaliação, demonstrando sua eficácia no problema de mapear de inundações. O resultado vai ao encontro das características positivas do classificador que é ser robusto e livre da influência ou da sensibilidade de parâmetros (TANG *et al.*, 2021), sendo necessário determinar apenas dois parâmetros: o número de árvores de decisão geradas e o número de variáveis para cada árvore de decisão. Em uma comparação com múltiplos modelos de aprendizado de máquina para a previsão de susceptibilidade de inundação, Gharakhanlou e Perez (2023) também encontraram o RF como o modelo com melhor desempenho.

No entanto, é importante ressaltar que a escolha do modelo mais adequado pode variar dependendo do contexto específico do problema. Por exemplo, para o modelo *Gaussian Naive Bayes*, é necessário que os dados sejam independentes entre si e que tenham distribuição gaussiana, o que não acontece nesse caso, pois algumas das variáveis têm distribuições que não seguem o padrão gaussiano (ZHANG, 2004). A escolha do modelo deve preceder uma análise se os pré-requisitos do classificador são satisfeitos pelas características dos dados de entrada, se é necessário um pré-processamento ou se realmente o modelo não é indicado para este uso. Além disso, o teste de capacidade de extrapolação aparenta indicar que o bom desempenho desses modelos é bastante limitado ao conjunto dos dados de treinamento e que, caso haja necessidade de extrapolação, o modelo não manterá o nível de acurácia.

Figura 4 – Comparação de dados previstos e observados para modelos RF (a, c) e GB (b, d) para os eventos das datas de 26/10/1997 (a, b) e 05/12/2009 (c, d), com TRs associados de 5 e 42, respectivamente.



CONCLUSÕES

Nesse trabalho, foi conduzida uma análise comparativa de modelos de aprendizado de máquina aplicados no mapeamento de inundações. Nove modelos distintos foram treinados, utilizando doze variáveis independentes, obtidas principalmente através de sensoriamento remoto. Para a avaliação dos modelos, foram utilizadas múltiplas métricas de desempenho.

Após o treinamento dos nove modelos para nove eventos de inundação distintos, os modelos que apresentaram os melhores desempenhos, considerando-se as médias das métricas, foram *Random Forest* e *Gradient Boosting*. Esses dois modelos foram utilizados para simular dois eventos de inundação extremos, visando testes de generalização e os resultados indicaram uma queda acentuada nas métricas de avaliação.

Verificou-se que os modelos de aprendizado de máquina têm capacidade de representar inundações, mesmo sem grandes ajustes e calibração de parâmetros. Por outro lado, o bom desempenho na estimativa indicou estar atrelado ao seu treinamento e o uso desses modelos, em outro contexto, pode apresentar desempenho aquém do esperado. Para estudos futuros, sugere-se ampliar os testes e investigar os prós e contras de cada um dos modelos para o uso no contexto de mapeamento e previsão de extensões de inundações.

REFERÊNCIAS

ALVES, M.E.P., FAN, F.M., SIQUEIRA, V.A., FLEISCHMANN, S., LAIPELT, L., MATTE, G., BRÊDA, J.P.F., DE PAIVA, C.D., ARAUJO, A.A., 2021. Mapeamento de manchas de inundação utilizando modelagem hidrológica e hidrodinâmica em escala local, regional e continental. Presented at the XXIV SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, p. 10.

- BATES, P.D., DE ROO, A.P.J., 2000. A simple raster-based model for flood inundation simulation. *Journal of Hydrology* 236, 54–77. [https://doi.org/10.1016/S0022-1694\(00\)00278-X](https://doi.org/10.1016/S0022-1694(00)00278-X)
- BUCHHORN, M., LESIV, M., TSENDBAZAR, N.-E., HEROLD, M., BERTELS, L., SMETS, B., 2020. Copernicus Global Land Cover Layers—Collection 2. *Remote Sensing* 12, 1044. <https://doi.org/10.3390/rs12061044>
- CHANG, V., GANATRA, M.A., HALL, K., GOLIGHTLY, L., XU, Q.A., 2022. An assessment of machine learning models and algorithms for early prediction and diagnosis of diabetes using health indicators. *Healthcare Analytics* 2, 100118. <https://doi.org/10.1016/j.health.2022.100118>
- CHEN, W., LI, Y., XUE, W., SHAHABI, H., LI, S., HONG, H., WANG, X., BIAN, H., ZHANG, S., PRADHAN, B., AHMAD, B.B., 2020. Modeling flood susceptibility using data-driven approaches of naïve Bayes tree, alternating decision tree, and random forest methods. *Science of The Total Environment* 701, 134979. <https://doi.org/10.1016/j.scitotenv.2019.134979>
- CONFEDERAÇÃO NACIONAL DE MUNICÍPIOS (CNM), 2022. Danos e prejuízos causados por desastres no Brasil entre 2013 a 2022 (Estudo Técnico).
- COPERNICUS CLIMATE CHANGE SERVICE, 2019. ERA5-Land hourly data from 2001 to present. <https://doi.org/10.24381/CDS.E2161BAC>
- EM-DAT, 2020. EM-DAT The International Disaster Database.
- FUNK, C., PETERSON, P., LANDSFELD, M., PEDREROS, D., VERDIN, J., SHUKLA, S., HUSAK, G., ROWLAND, J., HARRISON, L., HOELL, A., MICHAELSEN, J., 2015. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Sci Data* 2, 150066. <https://doi.org/10.1038/sdata.2015.66>
- GHARAKHANLOU, M.N., PEREZ, L., 2023. Flood susceptible prediction through the use of geospatial variables and machine learning methods. *Journal of Hydrology* 617, 129121. <https://doi.org/10.1016/j.jhydrol.2023.129121>
- HENGL, T., 2018. Soil texture classes (USDA system) for 6 soil depths (0, 10, 30, 60, 100 and 200 cm) at 250 m. <https://doi.org/10.5281/ZENODO.1475451>
- KAISER, M., GÜNNEMANN, S., DISSE, M., 2022. Regional-scale prediction of pluvial and flash flood susceptible areas using tree-based classifiers. *Journal of Hydrology* 612, 128088. <https://doi.org/10.1016/j.jhydrol.2022.128088>
- LI, X., YAN, D., WANG, K., WENG, B., QIN, T., LIU, S., 2019. Flood Risk Assessment of Global Watersheds Based on Multiple Machine Learning Models. *Water* 11, 1654. <https://doi.org/10.3390/w11081654>
- LIU, R., CHEN, Y., WU, J., GAO, L., BARRETT, D., XU, T., LI, X., LI, L., HUANG, C., YU, J., 2017. Integrating Entropy-Based Naïve Bayes and GIS for Spatial Evaluation of Flood Hazard: Bayes-Based Spatial Evaluation of Flood Hazard. *Risk Analysis* 37, 756–773. <https://doi.org/10.1111/risa.12698>
- MAILLARD, P., GOMES, M.F., PÔSSA, É.M., PAULA, R.S. DE, 2022. Challenges of defining the floodplain through the “mean ordinary flood line” approach using remote sensing in Brazil: a case study of the São Francisco River. *RBRH* 27, e5. <https://doi.org/10.1590/2318-0331.272220210110>

- MCFEETERS, S.K., 1996. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing* 17, 1425–1432. <https://doi.org/10.1080/01431169608948714>
- MUDASHIRU, R.B., SABTU, N., ABUSTAN, I., BALOGUN, W., 2021. Flood hazard mapping methods: A review. *Journal of Hydrology* 603, 126846. <https://doi.org/10.1016/j.jhydrol.2021.126846>
- NASA JPL, 2020. NASADEM Merged DEM Global 1 arc second V001. https://doi.org/10.5067/MEASURES/NASADEM/NASADEM_HGT.001
- PEDREGOSA, F., VAROQUAUX, G., GRAMFORT, A., MICHEL, V., THIRION, B., GRISEL, O., BLONDEL, M., PRETTENHOFER, P., WEISS, R., DUBOURG, V., VANDERPLAS, J., PASSOS, A., COURNAPEAU, D., BRUCHER, M., PERROT, M., DUCHESNAY, E., 2011. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research* 12, 2825–2830.
- PEKEL, J.-F., COTTAM, A., GORELICK, N., BELWARD, A.S., 2016. High-resolution mapping of global surface water and its long-term changes. *Nature* 540, 418–422. <https://doi.org/10.1038/nature20584>
- RASCHKA, S., LIU, Y., MIRJALILI, V., DZHULGAKOV, D., 2022. Machine learning with PyTorch and Scikit-Learn: develop machine learning and deep learning models with Python. Packt Publishing, Birmingham.
- SIQUEIRA, V.A., PAIVA, R.C.D., FLEISCHMANN, A.S., FAN, F.M., RUHOFF, A.L., PONTES, P.R.M., PARIS, A., CALMANT, S., COLLISCHONN, W., 2018. Toward continental hydrologic–hydrodynamic modeling in South America. *Hydrol. Earth Syst. Sci.* 22, 4815–4842. <https://doi.org/10.5194/hess-22-4815-2018>
- TADONO, T., ISHIDA, H., ODA, F., NAITO, S., MINAKAWA, K., IWAMOTO, H., 2014. Precise Global DEM Generation by ALOS PRISM. *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci.* II–4, 71–76. <https://doi.org/10.5194/isprsannals-II-4-71-2014>
- TANG, X., MACHIMURA, T., LIU, W., LI, J., HONG, H., 2021. A novel index to evaluate discretization methods: A case study of flood susceptibility assessment based on random forest. *Geoscience Frontiers* 12, 101253. <https://doi.org/10.1016/j.gsf.2021.101253>
- TIAMPO, K.F., HUANG, L., SIMMONS, C., WOODS, C., GLASSCOE, M.T., 2022. Detection of Flood Extent Using Sentinel-1A/B Synthetic Aperture Radar: An Application for Hurricane Harvey, Houston, TX. *Remote Sensing* 14, 2261. <https://doi.org/10.3390/rs14092261>
- WANG, D., WILLIS, D.R., YIH, Y., 2022. The pneumonia severity index: Assessment and comparison to popular machine learning classifiers. *International Journal of Medical Informatics* 163, 104778. <https://doi.org/10.1016/j.ijmedinf.2022.104778>
- WANG, H., WANG, H., WU, Z., ZHOU, Y., 2021. Using Multi-Factor Analysis to Predict Urban Flood Depth Based on Naive Bayes. *Water* 13, 432. <https://doi.org/10.3390/w13040432>
- YAMAZAKI, D., IKESHIMA, D., SOSA, J., BATES, P.D., ALLEN, G.H., PAVELSKY, T.M., 2019. MERIT Hydro: A High-Resolution Global Hydrography Map Based on Latest Topography Dataset. *Water Resour. Res.* 55, 5053–5073. <https://doi.org/10.1029/2019WR024873>
- ZHANG, H., 2004. The Optimality of Naive Bayes. *American Association for Artificial Intelligence* 1, 6.