

Flood Sensitivity Assessment Analysis Using Random Forest and Artificial Neural Network: A Case Study of Ilam Province

Farzaneh Gholami¹, Mojgan Entezari^{2*} , Reza Zakeri Nejad³, Haji Karimi⁴

1. PhD Student, Department of Physical Geography, Faculty of Geographical Sciences and Planning, University of Isfahan, Iran.

2. **Corresponding Author**, Professor, Department of Physical Geography, Faculty of Geographical Sciences and Planning, University of Isfahan, Iran.

Email: m.entezari@geo.ui.ac.ir ORCID: <https://orcid.org/0000-0003-0014-0209>

3. Assistant Professor of GIS and RS, Department of Physical Geography, Faculty of Geographical Sciences and Planning, University of Isfahan, Iran

4. Professor of Hydrogeology, Faculty of Agriculture, Ilam University, Ilam, Iran

Article Info	ABSTRACT
Article type: Research Article Article history: Received: 03 May 2025 Revised: 21 October 2025 Accepted: 07 November 2025 Published: 12 September 2026 Keywords: Machine Learning, Flood Sensitivity Map, Random Forest, Artificial Neural Network, Ilam Province.	Flood is one of the most catastrophic natural hazards worldwide that can easily have devastating effects on human lives and property. The frequent occurrence of this hazard makes it necessary to develop accurate flood hazard maps for better information dissemination and disaster preparedness and mitigation. The proposed research work is to analyze the flood susceptibility assessment in a mountainous environment. Therefore, this study aims to apply machine learning models (MLM) and geographic information systems (GIS) techniques to predict flood hazard areas in Ilam province. Two ML algorithms were used for flood susceptibility mapping of Ilam province: random forests (RF) and artificial neural networks (ANN). Sixteen continuous parameters and different categorical variables were identified to assess the correlation between these variables and flood events in the study area and were used as inputs to run the two models. A total of 1042 flood and non-flood points were randomly selected, 70% and 30% of which were used as training and validation datasets. Also, the results of the error rate of the proposed algorithms were considered, clearly showing that in the RF model, MAE, which is equal to 0.0889, and RMSE equal to 0.1872, have the lowest value, R2, which is equal to 0.8423, has the highest value, which performed better compared to the ANN model. The value of the research lies in the fact that the proposed models can also be used to assess natural disasters such as earthquakes, landslides, etc. In addition, this work makes a significant contribution to the efforts to reduce the risk of natural disasters. Therefore, it will help to increase environmental sustainability.
How to Cite: Gholami, F. , Entezari, M. , Zakeri Nejad, R. and Karimi, H. (2026). Flood Sensitivity Assessment Analysis Using Random Forest and Artificial Neural Network: A Case Study of Ilam Province. <i>Journal of Natural Environmental Hazards</i>, 15 (49), 25-54.	
	© The Author/Authors Publisher: University of Sistan and Baluchestan
DOI: 10.22111/jneh.2025.51893.2111	

EXTENDED ABSTRACT

INTRODUCTION

Flooding is one of the most destructive natural disasters in the world due to its severe property destruction and loss of life (Zanchetta & Coulibaly, 2020), and causes severe damage to infrastructure worldwide every year (Desai et al., 2015). Awareness of the flood phenomenon and its consequences is crucial for controlling and reducing flood risk (Marz et al., 2010). Flood susceptibility maps facilitate risk management decision-making (Wang et al., 2020). The Niger Basin was assessed using three machine learning models and twenty factors. It was found that areas near the river are more prone to flooding, and the extreme gradient boosting model performed best (Adeyemi & Komolafe, 2025). The Ili River Basin was investigated using machine learning models, and about 58.8% of the basin is located in flood-prone areas (Zhang et al., 2025). Ilam Province is one of the flood-prone areas of the country which can be He pointed out the November 2015 flood and the spring 2019 flood, which were unprecedented in the last 100 years and caused widespread destruction of homes and urban and rural infrastructure. Despite warnings and precautions, the November 2015 flood claimed the lives of several people in late 2019 (Salamat Hormozi et al., 2017).

DATA AND METHODOLOGY

The method of the present research includes creating a flood inventory map, identifying variables affecting floods and multi-lineage detection, validation, and accuracy analysis, or evaluation of flood sensitivity maps, etc. The models used to produce flood sensitivity index maps include the random forest model and the artificial neural network. The results of machine learning prediction and statistical modeling are significantly affected by the accuracy of historical flood location data (Liu et al., 2021). Flood-vulnerable areas in this model are divided into two zones based on historical and geoenvironmental data (Benkirane et al., 2020). Due to the topography and mountainous nature of the region, as well as the lack of Sentinel 1 satellite images at the time of the flood in the area, Google Earth Engine software did not perform well. For this reason, and using expert opinions, the Maxent model was used to extract flood points. Here, the geographical locations of 424 historical floods were taken from the Regional Water Organization of Ilam Province, and the Maxent model was used to prepare a flood inventory map. These floods were divided into two groups. The first group included 70% of the flood data and was used as the training dataset, and the second group included 30% of the remaining data and was used as the validation dataset. In addition, 617 flood-free points were randomly selected from high-altitude areas with low or no flood probability. In this study, R software was used to determine the importance of parameters, and two models, RF and ANN, were implemented in the R programming environment.

RESULTS AND DISCUSSION

16 input layers were entered as independent variables into the modeling process. The importance of all factors was determined and is shown in Figure 1. The relevance of each factor for both models was assessed using R software.




Figure 1: Relative importance of conditioning factors: (a) RF. (b) ANN Source: Authors

Using criteria such as MAE, R-squared, and RMSE, the model results were quantitatively validated against the flood inventory map. Table 1.

Table 1: Accuracy evaluation of the two RF and ANN models for training data through different error criteria

Model	RF	ANN
RMSE	0.1872	0.2591
R squared	0.8407	0.7056
MAE	0.0889	0.1628

Flood susceptibility maps were generated for both the random forest and artificial neural network models. The maps showed a continuous probability scale from 0 to 1.

Table 2: Flood susceptibility statistics with the RF and ANN models

Percentage(%)	Area (km2)	Flood susceptibility	Model
10.2	1958.08	High	ANN
1.8	355.158	Moderate	
88	16933.53	None/Low	
13.9	2687.99	High	RF
23.2	4460.82	Moderate	
62.9	12097.98	None/Low	

CONCLUSION

The random forest and artificial neural network models were built using a spatial database, whose data includes 16 topographic and geoenvironmental factors affecting floods and 1041 previous flood events. The experiments did not show evidence of multicollinearity between the identified conditioning factors. The validation findings showed that the two models performed significantly better. However, RF was more efficient than ANN in terms of computational efficiency, prediction accuracy, and other evaluation criteria. This was shown by the value of $R^2 = 0.8407$. This is because training the model with RF requires less execution time. The identification of key factors such as land use, elevation, and topographic wetness index (TWI) has enhanced the understanding of flood dynamics in the study area, and the results also showed that approximately 10.2% to 13.9% of the total area is highly vulnerable to flooding.

REFERENCES

References (in Persian)

Salamat Hormozi, Vahid, Omidvar, Kamal, Kavsi, Reza, Hamzenejad. Mojtaba, (2017). Identification and synoptic-dynamic analysis of atmospheric patterns of the November 2015 flood in Ilam and Lorestan provinces. *Newar.* , 27-9, (97-96)41, 27-9. [In Persian]

References (in English)

- Adeyemi, A. B., & Komolafe, A. A. (2025). Flood hazard zones prediction using machine-learning-based geospatial approach in the lower Niger River basin, Nigeria. *Natural Hazards Research*, 5(2), 399–412. <https://doi.org/10.1016/j.nhres.2025.01.002>
- Arora, A., Arabameri, A., Pandey, M., Siddiqui, M. A., Shukla, U. K., Bui, D. T., ... & Bhardwaj, A. (2021). Optimization of state-of-the-art fuzzy-metaheuristic ANFIS-based machine learning models for flood susceptibility prediction mapping in the Middle Ganga Plain, India. *Science of the Total Environment*, 750, 141565. <https://doi.org/10.1016/j.scitotenv.2020.141565>
- Benkirane, M., Laftouhi, N. E., El Mansouri, B., Salik, I., Snineh, M., El Ghazali, F. E., ... & Zamrane, Z. (2020). An approach for flood assessment by numerical modeling of extreme hydrological events in the Zat watershed (High Atlas, Morocco). *Urban Water Journal*, 17(5), 381-389.
- Desai, B., Maskrey, A., Peduzzi, P., De Bono, A., & Herold, C. (2015). Making development sustainable: the future of disaster risk management, global assessment report on disaster risk reduction.
- Liu, J., Wang, J., Xiong, J., Cheng, W., Sun, H., Yong, Z., & Wang, N. (2021). Hybrid models incorporating bivariate statistics and machine learning methods for flash flood susceptibility assessment based on remote sensing datasets. *Remote Sensing*, 13(23), 4945.
- Merz, B., Kreibich, H., Schwarze, R., & Thieken, A. (2010). Review article" Assessment of economic flood damage". *Natural Hazards and Earth System Sciences*, 10(8), 1697-1724.
- Mishra, A., Mukherjee, S., Merz, B., Singh, V. P., Wright, D. B., Villarini, G., ... & Stedinger, J. R. (2022). An overview of flood concepts, challenges, and future directions. *Journal of Hydrologic Engineering*, 27(6), 03122001.
- Sarkar, D., & Mondal, P. (2020). Flood vulnerability mapping using frequency ratio (FR) model: a case study on Kulik river basin, Indo-Bangladesh Barind region. *Applied Water Science*, 10(1), 1-13.
- Wang, Y., Fang, Z., Hong, H., & Peng, L. (2020). Flood susceptibility mapping using convolutional neural network frameworks. *Journal of Hydrology*, 582, 124482.
- Zanchetta, A. D., & Coulibaly, P. (2020). Recent advances in real-time pluvial flash flood forecasting. *Water*, 12(2), 570.
- Zhang, M., Fu, X., Liu, S., & Zhang, C. (2025). Integrating Remote Sensing and Machine Learning for Actionable Flood Risk Assessment: Multi-Scenario Projection in the Ili River Basin in China Under Climate Change. *Remote Sensing*, 17(7), 1189.

مجله علمی پژوهشی مخاطرات محیط طبیعی، دوره ۱۵، شماره ۴۹، شماره پیاپی ۳، مهر ۱۴۰۵

تحلیل ارزیابی حساسیت به سیل با استفاده از جنگل تصادفی و شبکه عصبی

مصنوعی: مطالعه موردی استان ایلام

فرزانه غلامی^۱، مژگان انتظاری^{۲*} ID، رضا ذاکری نژاد^۳، حاجی کریمی^۴

۱. دانشجوی دکتری ژئومورفولوژی، دانشکده علوم جغرافیا و برنامه‌ریزی، دانشگاه اصفهان، اصفهان
۲. استاد گروه جغرافیای طبیعی، دانشکده علوم جغرافیایی و برنامه‌ریزی، دانشگاه اصفهان (نویسنده مسئول)
ایمیل: m.entezari@geo.ui.ac.ir ORCID: <https://orcid.org/0000-0003-0014-0209>
۳. استادیار گروه جغرافیای طبیعی، دانشکده علوم جغرافیایی و برنامه‌ریزی، دانشگاه اصفهان
۴. استاد هیدروژئولوژی، دانشکده کشاورزی، دانشگاه ایلام، ایلام

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی تاریخ دریافت: ۱۴۰۴/۰۲/۱۳ تاریخ ویرایش: ۱۴۰۴/۰۷/۲۹ تاریخ پذیرش: ۱۴۰۴/۰۸/۱۶ تاریخ انتشار: ۱۴۰۵/۰۶/۲۲ واژه‌های کلیدی: یادگیری ماشین، نقشه حساسیت سیل، جنگل تصادفی، شبکه عصبی مصنوعی، استان ایلام.	سیل یکی از مخاطرات طبیعی فاجعه‌بار در سراسر جهان است که به راحتی می‌تواند اثرات مخربی بر جان و دارایی انسان‌ها داشته باشد. رویدادهای مکرر این خطر، توسعه نقشه‌های دقیق خطر سیل را برای اطلاع‌رسانی بهتر و آمادگی در برابر بلایا و کاهش آن ضروری می‌سازد. کار تحقیقاتی پیشنهادی، جهت تجزیه و تحلیل ارزیابی حساسیت سیل در یک محیط کوهستانی است. بنابراین، این مطالعه با هدف به کارگیری مدل‌های یادگیری ماشین (MLM) و فن‌های سیستم‌های اطلاعات جغرافیایی (GIS) برای پیش‌بینی مناطق خطر سیل در استان ایلام است. دو الگوریتم ML برای نقشه‌برداری حساسیت سیل استان ایلام استفاده شد: جنگل‌های تصادفی (RF) و شبکه عصبی مصنوعی (ANN). شازده پارامتر پیوسته و متغیرهای طبقه‌بندی شده مختلف را برای ارزیابی همبستگی بین این متغیرها و حوادث سیل در منطقه مورد مطالعه شناسایی و به عنوان ورودی برای اجرای دو مدل استفاده شدند. در مجموع، ۱۰۴۲ نقطه سیل و غیرسیل تصادفی انتخاب شدند که ۷۰٪ و ۳۰٪ به عنوان مجموعه داده‌های آموزشی و اعتبارسنجی استفاده شدند. همچنین، نتایج نرخ خطای الگوریتم‌های پیشنهادی در نظر گرفته شده به وضوح نشان داد که در مدل RF، MAE که برابر با ۰/۰۸۸۹ و RMSE برابر با ۰/۱۸۷۲ دارای کمترین مقدار، R2 که برابر ۰/۸۴۲۳ بیشتر مقدار که در مقایسه با مدل ANN عملکرد بهتری داشت. ارزش پژوهش در این واقعیت نهفته است که مدل‌های پیشنهادی می‌تواند برای ارزیابی بلایای طبیعی مانند زلزله، رانش زمین و غیره نیز مورد استفاده قرار گیرد. علاوه بر این، این کار کمک قابل توجهی به تلاش برای کاهش خطر بلایای طبیعی می‌کند. بنابراین، این امر به افزایش پایداری محیطی کمک خواهد کرد.

استناد: غلامی، فرزانه، اعتباری، مژگان، ذاکر نژاد، رضا و کریمی، حاجی. (۱۴۰۵). تحلیل ارزیابی حساسیت به سیل با استفاده از جنگل تصادفی و شبکه عصبی مصنوعی: مطالعه موردی استان ایلام. *مخاطرات محیط طبیعی*، ۱۵ (۴۹)، ۵۴-۲۵.

ناشر: دانشگاه سیستان و بلوچستان

© نویسنده / نویسندگان



DOI: 10.22111/jneh.2025.51893.2111

مقدمه

مخاطرات طبیعی روز به روز در حال افزایش است و به صورت قابل توجهی در سطح جهانی و ملی مورد توجه قرار گرفته است (آدین^۱ و همکاران، ۲۰۱۳). سیل به دلیل تخریب شدید اموال و تلفات جانی حاصل از آن (وانگ^۲ و همکاران ۲۰۱۱؛ زانچتا و کولیبالی^۳، ۲۰۲۰)، از مخرب ترین، شایع ترین (میشرا^۴ و همکاران، ۲۰۲۲) و پرهزینه ترین بلاهای طبیعی در جهان است (تریپاتی^۵، ۲۰۱۵؛ آرورا^۶ و همکاران، ۲۰۲۱) و هر ساله خسارت های شدیدی به زیرساخت ها در سراسر جهان وارد می کند و همچنین موجب تضعیف اقتصاد در سطح کلان می گردد (دسای^۷ و همکاران، ۲۰۱۵). بر اساس داده های آماری پایگاه داده رویدادهای اضطراری (EM-DAT) در سال ۲۰۲۱، حدود ۱۷۵۰۰۰ مرگ و میر به دلیل وقوع سیل اتفاق افتاد و ۲،۲ میلیارد نفر در طی ۲۷ سال، تحت تاثیر مخاطرات ناشی از سیل قرار گرفتند. علاوه بر این، براساس استراتژی های بین المللی کاهش بلایا (UNISDR) در سال ۲۰۱۵، سیل هر ساله باعث ایجاد حدود ۳۰ میلیارد دلار خسارت به آمریکا وارد می کند، همچنین عاملی مؤثر بر تغییرات جمعیتی محسوب می شود (نو و همکاران، ۲۰۲۲). سیل بر اثر عوامل و دلایل طبیعی و انسانی رخ می دهد (چانگ و چن^۹، ۲۰۱۶). علاوه بر رویدادهای شدید آب و هوایی ناشی از تغییرات اقلیمی، فعالیت های انسانی سهم زیادی در بروز سیل های شدید مکرر دارند. فعالیت های انسانی، مانند تغییر سریع پوشش زمین، رشد جمعیت و ساخت جاده، سطوح غیر قابل نفوذ را افزایش داده و منجر به سیل های رایج و شدیدتر می شود (رحمان^{۱۰} و همکاران، ۲۰۲۱). به تازگی دخالت انسان در محیط زیست باعث وقوع سیلاب شده است که این سیلاب ها بیش از قبل رخ می دهد و اساساً به دلیل تخریب محیط زیست در مقیاس وسیع به واسطه رشد جمعیت، تجاوز به دشت های سیلابی کنار رودخانه، شهرنشینی، جنگل زدایی و غیره است (باند^{۱۱} و همکاران ۲۰۲۰). آگاهی از پدیده سیل و پیامدهای آن برای کنترل سیل، کاهش خطر و به طور کلی مدیریت سیل بسیار مهم است. همچنین، پیش بینی سیل جهت پیش بینی خسارت و کاهش خطرات ضروری است و استفاده از علوم مختلف مانند جغرافیا، هیدرولوژی، هیدرولیک، مهندسی عمران و اقتصاد محیط زیست برای درک این پدیده ضروری است (مرز^{۱۲} و همکاران، ۲۰۱۰).

نقشه حساسیت سیل، تصمیم گیری مدیریت ریسک را تسهیل می کند و به اجرای استراتژی های کاهش سیل کمک می کند و راهنمایی برای توسعه پوشش زمین، استفاده از زمین در مناطق آسیب پذیر سیل ارائه می کند (وانگ^{۱۳} و همکاران، ۲۰۲۰). بخش مهمی از مدیریت ریسک بلایا، ترسیم حساسیت به سیل است که به دولت ها و جوامع در پیش بینی، واکنش و کاهش اثرات مخرب حوادث سیل کمک می کند. فراوانی و شدت سیل در حال افزایش می باشد و توسعه مدیریت مؤثر در زمینه سیل را ضروری می نماید (کومار^{۱۴} و همکاران، ۲۰۱۴). مدل های پیش بینی سیل

¹ Uddin² Wang³ Zanchetta & Coulibaly⁴ Mishra⁵ Tripathi⁶ Arora⁷ Desai⁸ Nevo⁹ Chang & Chen¹⁰ Rahman¹¹ Band¹² Merz¹³ Wang¹⁴ Kumar

اهمیت چشمگیری برای ارزیابی خطر و مدیریت رویدادهای شدید دارد. همچنین، پیش‌بینی قوی و دقیق به استراتژی‌های مدیریت منابع آب، پیشنهادات و تجزیه و تحلیل سیاست‌ها و مدل‌سازی تخلیه بیشتر کمک می‌کند (شیه^۱ و همکاران، ۲۰۱۷). نقشه‌برداری خطر سیل، یک عنصر ضروری جهت مدیریت ریسک سیل است (مرز و همکاران، ۲۰۱۰؛ متئو گارسیا^۲ و همکاران، ۲۰۲۱). بنابراین، انجام تحقیقات در رابطه آسیب‌پذیری سیل و توسعه اقدامات پیشگیرانه برای کاهش شدت آن ضروری است؛ زیرا می‌تواند برای به حداقل رساندن اثرات سیل مفید باشد. بنابراین، اقدامات کاهش سیل باید برای شناسایی مناطقی بسیار آسیب‌پذیر در برابر سیل متمرکز شود تا اثرات آن کاهش یابد. از این رو، به نقشه‌برداری حساسیت به سیل نیاز است تا بتواند اثرات سیل را کاهش دهد. فهرست سیل و نقشه‌های حساسیت به سیل اهمیت فراوانی در کاهش خطرات سیلاب و ایجاد بستری مناسب برای مدیریت صحیح سیلاب دارد. قابل درک است که جوامع همواره در تلاش بوده‌اند تا با استفاده از ابزارهای مدیریت سیل، احتمال وقوع سیل را کاهش دهند. عباس‌زاده تهرانی و همکاران (۱۳۸۹) در پژوهشی، میزان دبی سیلاب‌های حوضه آبریز رودخانه مادرسو (دوغ) از طریق به‌کارگیری RS و GIS بررسی کردند. نتایج نشان داد تغییرات کاربری اراضی بر کاهش میزان سیلاب منطقه تاثیرگذار بوده است. طهماسبی (۱۴۰۰) با استفاده از روش‌های کمی و به کمک نرم‌افزار Arc، Envi، GIS و Fragtats و روش‌های کیفی و فن‌های دلفی، وضعیت سیل‌خیزی شهر ایلام بررسی کرد. نتایج آن نشان داد که عملکرد، شوراهای شهر و سازمان‌های مدیریت بحران شهر، پاسخگوی احتمالی مقابله با بحران نیستند. لاهوتی نسب و قاسمیه (۱۴۰۳) با استفاده از مدل‌های DEMATEL-AHP و SVM سیل‌خیزی حوضه آبخیز برزک کاشان بررسی نمودند. نتایج نشان داد که عامل بارش مؤثرترین متغیر بر سیل‌خیزی است و مناطق شمال، شمال غرب و غرب حوضه دارای بیشترین پتانسیل در وقوع سیل و سیل‌خیزی هستند. سگیانتو^۳ و همکاران (۲۰۲۰) به شناسایی مناطق آسیب‌پذیر سیل و ارزیابی علل سیل در حوضه آبخیز تویونوم^۴، آچه جایا^۵ پرداختند. نتایج نشان داد افزایش چشمگیری در استفاده از زمین‌های مسکونی، زمین‌های بایر، مزارع برنج و تالاب‌ها (آب‌ها) داشته است و نفوذناپذیری و اشباح باعث افزایش خطرات سیل منطقه شده است.

شیرانی و ذاکری‌نژاد^۶ (۲۰۲۱) با استفاده از مدل خطی چندمتغیره مختلط تاپسیس به اولویت‌بندی ۲۴ زیرحوضه در حوضه جراحی-زهره^۷ در جنوب غربی ایران^۸ پرداختند. نتایج به‌دست‌آمده از تحلیل وزن‌دهی نشان داد که اطلاعات ناهمواری، شیب و بارندگی بیشترین تأثیر را بر رویدادهای سیل داشته است. حوضه‌های فرعی سیدیون، امام‌زاده جعفر و تخت درازا^۹ بیشتر در معرض خطر سیل قرار دارد. سیدی^{۱۰} و همکاران (۲۰۲۲) در دو منطقه حوضه گرگانرود و کارون^{۱۱} در ایران^{۱۲}، نقشه مدل حساسیت سیل (FSM) را با ۲۱ پارامتر تهیه کردند و مدل جنگل آبشاری (CFM) در هر دو حوضه را ارزیابی کردند. نتایج حاصل‌شده با نتایج شش روش دیگر یادگیری ماشین از جمله ماشین بردار

¹ Xie

² Mateo-Garcia

³ Sugianto

⁴ Teunom

⁵ Aceh Jaya

⁶ Shirani & Zakerinejad

⁷ Jarahi-Zohre

⁸ IRAN

⁹ Seidyon, Emamzadeh Jafar, and Takht Deraza

¹⁰ Seydi

¹¹ Gorganrud and Karun

¹² Iran

پشتیبان (SVM)، شبکه عصبی عمیق (DNN)، جنگل تصادفی (RF)، دستگاه تقویت گرادیان نور (LightGBM)، درخت تصمیم (DT)، تقویت گرادیان شدید (XGBoost) و تقویت طبقه‌بندی (CatBoost) مقایسه شد. نتایج نشان داد که CFM بالاترین دقت را در مقایسه با سایر مدل‌ها در هر دو منطقه داشت. ساب^۱ و همکاران (۲۰۲۳) از سه فن یادگیری ماشین (RF، LightGBM و CatBoost) برای تهیه نقشه‌های حساسیت به سیل (FSMs) در حوضه رودخانه وی گیاتابون^۲ (VGTB) در ویتنام^۳ استفاده کردند. نقشه حساسیت سیل مدل‌ها نشان دادند که ۱۰ تا ۱۳ درصد از کل منطقه به شدت مستعد سیل است، مناطق پایین دست (اعم از شهری و کشاورزی) در سطوح بالایی و بسیار بالایی از حساسیت قرار دارد. صلواتی^۴ و همکاران (۲۰۲۳) با استفاده از رگرسیون بردار پشتیبان (SVR)، همراه با هسته خطی (LK)، طبقه‌بندی کننده پایه (BC) و بهینه‌سازی فرا پارامتری (HPO) در حوضه آبخیز هراز^۵ در استان مازندران^۶ ایران^۷ به بررسی و شناسایی مناطق مستعد سیل پرداختند. عامل شیب، فاصله از رودخانه بیشترین اهمیت را دارا بودند. همچنین، مدل SVR-HPO نسبت به دو مدل دیگر عملکرد بهتری داشت. با استفاده از مدل‌های نسبت فرکانس، منطق فازی (FL)، فرآیند تحلیل سلسله‌مراتبی مبتنی بر تصمیم‌گیری چندمعیاره و فرآیند تحلیل سلسله‌مراتبی فازی حساسیت سیل در حوضه آبریز جیا بهارالی^۸ بررسی شد. نتایج نشان داد که حدود یک سوم از حوضه یادشده در مناطق سیل‌خیز متوسط تا بسیار زیاد قرار دارد (دبنات^۹ و همکاران، ۲۰۲۴). حوضه رودخانه نیجر^{۱۰} در نیجریه^{۱۱} با استفاده از مدل ماشین بردار پشتیبان (SVM)، تقویت گرادیان شدید (XGBoost) و شبکه‌های عصبی مصنوعی (ANN) و بیست عوامل تأثیرگذار جهت شناسایی مناطق مستعد سیل ارزیابی شد. نقشه‌های خطر سیل نشان داد که مناطق نزدیک رودخانه، به‌ویژه در بخش مرکزی و جنوبی حوضه، بیشتر مستعد سیل هستند و مدل تقویت گرادیان شدید بهترین عملکرد داشت (آدیمی و کومولافه^{۱۲}، ۲۰۲۵). با ادغام نقاط قوت شبکه‌های عصبی کانولوشنال (CNN)، شبکه‌های کپسولی (CapsNet^{۱۳}) و الگوریتم بهینه‌سازی نهنگ (WOA^{۱۴})، مناطق پرخطر شهرهای گوانگژو، شنژن و فوشان^{۱۵} شناسایی شد. یافته‌ها نشان داد مناطق پرخطر بیشتر در مناطق مرکزی شهرهای گوانگژو، شنژن و فوشان متمرکز شده است. عوامل فاصله تا بیمارستان‌ها و فاصله تا بدنه‌های آبی به‌عنوان محرک‌های اصلی خطر سیل شناسایی شدند، درحالی‌که عوامل طبیعی مانند شاخص انتقال رسوب، شاخص قدرت جریان و شاخص رطوبت توپوگرافی تأثیرات نسبتاً کمتری داشتند (وانگ^{۱۶} و همکاران، ۲۰۲۵). حوضه رودخانه ایلی^{۱۷} در چین^{۱۸} با استفاده از مدل‌های یادگیری ماشین جنگل تصادفی و تقویت گرداین شدید^{۱۹} بررسی شد. نتایج نشان داد

¹ Saber

² Vu Gia-Thu Bon

³ Vietnam

⁴ Salvati

⁵ Haraz

⁶ Mazandaran

⁷ Iran

⁸ Jia Bharali

⁹ Debnath

¹⁰ Niger

¹¹ Nigeria

¹² Adeyemi & Komolafe

¹³ capsule networks

¹⁴ whale optimization algorithm

¹⁵ Guangzhou, Shenzhen, and Foshan

¹⁶ Wang

¹⁷ Ili

¹⁸ China

¹⁹ XGBoost, Random Forest (RF)


که حدود ۵۸,۸٪ از حوضه در مناطق پرخطر و بسیار پرخطر سیل واقع شده است (ژانگ^۱ و همکاران، ۲۰۲۵). استان ایلام یکی از مناطق سیل‌خیز کشور است که با توجه به شدت و مدت بارندگی در حین یا پس از بارندگی، مقدار دبی رودخانه‌ها به سرعت بالا آمده و آب از بستر عادی رودخانه‌ها سرریز نموده و باعث سیلابی شدن منطقه می‌شود. می‌توان به سیل آبان ۱۳۹۴ و همچنین سیل بهار ۱۳۹۸ اشاره نمود که در ۱۰۰ سال اخیر بی‌سابقه بودند و تخریب گسترده منازل و زیرساخت‌های شهری و روستایی را به همراه داشته است و علی‌رغم هشدارها و تمهیدات انجام گرفته، سیل آبان ۱۳۹۴ و اواخر سال ۱۳۹۸ جان چندین نفر را گرفت (سلامتی هرمزی و همکاران، ۱۳۹۶).

داده‌ها و روش‌ها

محدوده مورد مطالعه

استان ایلام در غرب کشور ایران، هم مرز با کشور عراق می‌باشد که مساحتی حدود ۲۰,۱۵۰ کیلومتر مربع و ۲,۱ درصد از مساحت کل کشور را پوشش می‌دهد. با مختصات ۳۱ درجه و ۵۸ دقیقه تا ۳۴ درجه و ۱۵ دقیقه عرض شمالی و ۴۵ درجه و ۲۴ دقیقه تا ۴۸ درجه و ۱۰ دقیقه طول واقع است شکل (۱). نواحی شمال و شمال شرق استان ایلام کوهستانی و نواحی جنوب غرب و غرب استان از اراضی پست و کم ارتفاع تشکیل یافته است. توده هوای غربی از دریای مدیترانه و دریای سیاه باعث بارندگی‌های پاییزی و زمستانی در استان می‌شوند و جریانات سودانی و دریای سرخ و صحرای عربستان نیز در بارش‌های زمستانی و بهاری مؤثرند و در تابستان سبب گرم شدن هوا می‌شود. براساس اطلاعات و آمار ثبت شده در ایستگاه سینوپتیک ایلام، حداکثر مطلق دما ۴۰/۶ درجه سلسیوس و حداقل مطلق دما ۱۲/۶- درجه سلسیوس بوده و میانگین بارندگی سالانه این ایستگاه ۵۹۵ میلی‌متر است و دارای آب‌وهوای خشک و نیمه‌خشک می‌باشد. به‌طورکلی، استان ایلام به لحاظ واحدهای ژئومورفولوژیکی به دو واحد (کوهستان) شامل تاقدیس‌های کبیرکوه، دینارکوه، مانشت، قلارنگ و ... (و دشت) شامل دشت عباس، دشت دهلران و ناودیس‌های مرکزی تقسیم می‌شود. از جمله مهم‌ترین رودخانه‌هایی که در محدوده جغرافیایی استان ایلام که از دامنه‌های شمالی و جنوبی کبیرکوه سرچشمه می‌گیرند، می‌توان به رودخانه سیمره، دویرج، چنگوله، آبدانان، چناره، میمه و سیاه گاوو... اشاره کرد (نیک‌پور و همکاران، ۱۳۹۳). استان ایلام یکی از استان‌های سیل‌خیز است که به دلیل ویژگی‌های توپوگرافی و اقلیمی معمولاً تحت تأثیر سیلاب قرار می‌گیرد. سیل‌های متعددی در گذشته رخ داده که می‌توان به سیلاب‌های سال‌های ۶۸-۷۳ - ۹۴ - ۹۷-۹۸ و ۴۰۲ اشاره کرد و خسارات شدیدی به جان انسان‌ها و زیر بناها وارد کرده است.

¹ Zhang



شکل ۱: منطقه مورد مطالعه. منبع: نگارندگان

روش‌شناسی

روش‌شناسی شامل سازماندهی کلی این پژوهش است که شامل ایجاد نقشه موجودی سیل، شناسایی متغیرهای موثر بر سیل و تشخیص چندخطی، اعتبارسنجی و تحلیل دقت یا ارزیابی نقشه‌های حساسیت به سیل و غیره است. جدول (۱). مدل‌های به‌کار برده‌شده برای تولید نقشه شاخص حساس به سیل (FSI) عبارتند از مدل جنگل تصادفی و شبکه عصبی مصنوعی شکل (۲).

نقشه موجودی سیل

جهت موثر بودن استراتژی‌های مدیریت و کاهش سیل، درک و تجزیه و تحلیل نقشه موجودی سیل بسیار مهم است. وقوع سیل‌های گذشته، به‌عنوان متغیرهای ورودی مهم برای محاسبه حساسیت سیل عمل می‌کند (کاستاچ^۱ و همکاران، ۲۰۲۲). تولید نقشه فهرست موجودی سیل (FIM) به‌طور کلی، از داده‌های سیل قبلی یک منطقه ساخته شده است (احمد^۲ و همکاران، ۲۰۲۲). مدیریت سیل به‌طور ویژه نیاز به درک خوبی از روندهای تاریخی سیل، انتظارات آینده و شناسایی مکان‌هایی دارد که احتمالاً تحت تأثیر سیل قرار می‌گیرند. نقشه‌برداری سیل، اطلاعاتی فراهم می‌کند تا اطمینان حاصل شود که آمادگی، واکنش و بازایی به‌طور مؤثر برای کاهش تأثیر سیل انجام شده است (پلات^۳، ۲۰۰۲). نقشه‌برداری موجودی سیل اولین گام به سمت نقشه برداری حساسیت است (رحمتی و همکاران، ۲۰۱۶). تهیه نقشه موجودی سیل نیازمند یک رویکرد داده محور است. برای آموزش و اعتبارسنجی موثر مدل، موجودی سیل به‌عنوان یک جزء حیاتی عمل می‌کنند (اسلام^۴ و همکاران، ۲۰۲۱؛ مجددی^۵ و همکاران، ۲۰۱۷).

¹ Costache

² Ahmed

³ Plate

⁴ Islam


⁵ Mojaddadi

صحت رخدادهای گذشته سیل، دقت و قابلیت اطمینان آسیب‌پذیری سیل در آینده را تعیین می‌کند (سارکار و موندال^۱، ۲۰۲۰). نتایج پیش‌بینی یادگیری ماشین و مدل‌سازی آماری به‌طور قابل‌توجهی تحت تأثیر دقت داده‌های مکان سیل تاریخی قرار می‌گیرد (لیو^۲ و همکاران ۲۰۲۱). مناطق آسیب‌پذیر در برابر سیل، در این مدل، بر اساس داده‌های تاریخی و ژئومحیطی به دو منطقه (۱) غیرقابل سیل (۲) سیل‌خیز تقسیم می‌شوند (بنکیران^۳ و همکاران ۲۰۲۰). با توجه به توپوگرافی و کوهستانی بودن منطقه و همچنین نبود تصاویر ماهواره‌ای سنتینل ۱ در زمان وقوع سیل در منطقه، نرم‌افزار گوگل ارث انجین^۴ (GEE) عملکرد خوبی نداشتند. به همین دلیل و با استفاده از نظر کارشناسان، از مدل مکسنت جهت استخراج نقاط سیل استفاده شد. در اینجا، موقعیت جغرافیایی ۴۲۴ سیل تاریخی از سازمان آب منطقه‌ای استان ایلام و مدل مکسنت^۵ برای تهیه نقشه موجودی سیل گرفته شد. این سیلاب‌ها به دو گروه تقسیم شدند. گروه اول شامل ۷۰ درصد از داده‌های سیل بود که به‌عنوان مجموعه داده آموزشی استفاده شد و علاوه بر این، ۶۱۷ نقطه بدون سیل به‌طور تصادفی از مناطق مرتفع با احتمال کم سیل یا بدون سیل انتخاب شدند. تجزیه و تحلیل دقیق حساسیت سیل، مستلزم یک نقشه دقیق موجودی سیل است که مکان وقوع سیل را نشان دهد. در این مطالعه، ۴۲۴ نقطه مکان سیل شناسایی شد.

جدول ۱: عوامل موثر در سیلاب برای نگاشت حساسیت سیل

منابع	نقشه‌های مورد نیاز	داده ها
Search.asf.alaska.edu/##	ارتفاع، شاخص رطوبت توپوگرافی TWI، شاخص توان جریان SPI، شیب، جهت شیب، انحنا، تراکم شبکه زهکشی و فاصله از رودخانه دائمی، شاخص ناهمواری توپوگرافی، شاخص رطوبت متفاوت نرمالیزه‌شده، همگرایی، جهت جریان، زمین‌شناسی	۱ ALOSPALSAR (D.E.M./12.5 m)
Google Earth Engine	نقشه NDVI	۲ Sentinel 2 (10 m) Google Earth Engin
Google Earth Engine	نقشه LU/LC	۳ Land use/Land cover(10 m)
داده‌های هواشناسی	نقشه بارندگی	۴ داده‌های بارندگی
(مرکز داده ISRIC، اطلاعات خاک جهان)	بافت خاک	۵ داده‌های خاک
سازمان زمین‌شناسی ایران	زمین‌شناسی	۶ اطلاعات زمین‌شناسی

¹ Sarkar& Mondal² Liu³ Benkirane⁴ Google Earth Engine⁵ Maxent



شکل ۲: مواد و روش پژوهش منبع: نگارندگان


یافته‌های پژوهش

ارزیابی چندخطی

در این مطالعه، ما با این فرض پیش رفتیم که هیچ وابستگی خطی بین متغیرها وجود نخواهد داشت که تأثیر مخربی بر مدل‌های حساسیت منطقه مورد مطالعه داشته باشد شکل (۳). جدول (۲) نتایج تجزیه و تحلیل چندخطی ۱۶ عامل مناسب سیل را نشان می‌دهد. TOL همه متغیرهای مورد استفاده در این مطالعه بالاتر از ۰/۲۶۲ است که نشان‌دهنده عدم وجود چندخطی بین این متغیرها است. بنابراین، ما از همه آنها در مرحله مدل‌سازی استفاده کردیم.

جدول ۲: تجزیه و تحلیل چندخطی عوامل سیل ۱

متغیر	VIF	آمار خطی
		T_i
TWI	۱/۷۸	۰/۵۶۱
NDMI	۱/۲۶	۰/۷۹۰
NDVI	۱/۴۸	۰/۶۷۷
Rain	۱/۳۷	۰/۷۲۷
Slope	۱/۹۷	۰/۵۰۶
Soil	۲/۲۱	۰/۴۵۱
SPI	۱/۶	۰/۶۲۳
TRI	۱/۲۳	۰/۸۱۳
aspect	۱/۰۲	۰/۹۷۸
Curvature	۱/۳۶	۰/۷۳۳
distance_r	۱/۳۱	۰/۷۶۴
drainage_n	۱/۱۹	۰/۸۳۷
elvation	۳/۸۱	۰/۲۶۲
FlowDirect	۱/۰۳	۰/۹۷۲
geology	۱/۰۳	۰/۹۷۰
lulc	۱/۴۸	۰/۶۷۵



شکل ۳: نمودار تجزیه و تحلیل چندخطی متغیر

تعیین اهمیت پارامترها

الگوریتم‌های مختلفی برای تعیین اهمیت متغیرهای موثر بر یک پدیده وجود دارد. در این پژوهش از نرم‌افزار R برای تعیین اهمیت پارامترها استفاده شده است.

معرفی پارامترهای منتخب و نقشه‌های آن‌ها

شاخص‌های سیل بر اساس ویژگی‌ها، مقیاس منطقه مورد مطالعه و در دسترس بودن داده‌ها انتخاب شدند (بویی^۱ و همکاران، ۲۰۱۶). بر اساس ویژگی‌های سیلاب‌های تاریخی در منطقه مورد مطالعه و مشاهدات میدانی متعدد، ۱۶ عامل تأثیرگذار - ارتفاع، شیب، جهت شیب، فاصله از رودخانه‌ها، میانگین بارندگی ماهانه، کاربری زمین، بافت خاک، شاخص قدرت رودخانه، پوشش گیاهی، زمین‌شناسی، جهت جریان، شاخص رطوبت توپوگرافی، جهت جریان و انحنا برای نقشه‌برداری حساسیت سیل انتخاب شد. شرح مفصلی از داده‌ها و منابع آنها ارائه شده است و نقشه‌های همه عوامل انتخاب‌شده در شکل (۴) نشان داده شده است.

ارتفاع: ارتفاع یکی از پارامترهای پرکاربرد و یکی از عوامل کلیدی کنترل سیلاب یک منطقه است (بویی و همکاران، ۲۰۱۶). به‌طور معمول، ارتباط واضحی بین ارتفاع و سیل وجود دارد؛ زیرا مناطق با ارتفاعات پایین‌تر در مقایسه با مناطق با ارتفاعات بالاتر در معرض وقوع خطر سیل هستند (وانگ و همکاران، ۲۰۲۱؛ دو^۲ و همکاران، ۲۰۱۵) شکل (۴الف).

¹ Bui

² Dou

شیب: یکی از عوامل توپوگرافی است که در مطالعات هیدرولوژیکی موثر است. رابطه شیب با بارندگی این است که نفوذ بارندگی به‌طور مستقیم تحت تأثیر شیب است (رحمتی^۱ و همکاران، ۲۰۱۹). هر چه زاویه بیشتر باشد، نفوذ آب سطحی کمتر و سرعت جریان آب و رواناب بیشتر می‌شود (محمدی^۲ و همکاران، ۲۰۲۰). نشان‌دهنده تمایل زمین به ریختن آب به مناطق مجاور پایین‌تر است (گروبر و پکهام^۳، ۲۰۰۹). مناطق مستعد سیل بیشتر در زمین‌های مسطح یافت می‌شوند (چوبین^۴ و همکاران، ۲۰۱۹) شکل (۴ب).

جهت شیب: این عامل به‌طور کلی جهت پایین شیب (رحمتی و همکاران، ۲۰۱۹) را نشان می‌دهد. این هم بر شدت بارندگی و هم بر توسعه مورفولوژیکی تأثیر می‌گذارد (یوسفی^۵ و همکاران، ۲۰۲۰). جهت زمین می‌تواند نقش مهمی در نقشه حساسیت سیل داشته باشد؛ زیرا به جهت جریان آب مربوط می‌شود (اسلام و همکاران، ۲۰۲۱) شکل (۴پ).

انحنای رودخانه: انحنای رودخانه از سه قسمت تشکیل شده است: سطح مقعر، محدب و صاف. به‌عنوان عواملی که بر جریان رواناب موثر است و می‌تواند در تشخیص مناطق حساس به سیل مفید باشد (لی^۶ و همکاران، ۲۰۱۲a). انحنای پلان بر جریان آب در یک منطقه معین تأثیر می‌گذارد. پس از محاسبه این عامل، مقادیر صفر نشان‌دهنده خطر بسیار مهم سیل است. شکل (۴ت).

فاصله از رودخانه: جریان رودخانه‌ها مسیرهای اصلی تخلیه سیل هستند (اوپرمن^۷ و همکاران، ۲۰۰۹)؛ زیرا مناطق آسیب‌پذیر سیل معمولاً در مجاورت رودخانه و نه‌رها واقع شده‌اند (آندریانی^۸ و همکاران، ۲۰۲۱). شکل (۴ث).

تراکم شبکه زهکشی: هنگامی بارندگی، تراکم زهکشی بر جریان‌های اوج تأثیر می‌گذارد. سیلاب‌های منطقه‌ای اغلب به مقدار پیک دبی و منطقه زهکشی مرتبط هستند (آیالو و کرایفسکی^۹، ۲۰۱۷). سیستم‌های زهکشی ضعیف اغلب منجر به طغیان رودخانه و جاری شدن سیل مداوم در یک منطقه می‌شود (۲۰۱۸ کومولافه^{۱۰} و همکاران، ۲۰۱۸). شکل (۴ج).

بارندگی: بارش متغیر اصلی هیدرولوژیکی است که جو را با فرایندهای سطحی زمین پیوند می‌دهد (۱۰ تگاواراپو^{۱۱}، ۲۰۱۲). و با احتمال وقوع سیل تأثیر می‌گذارد (ورما^{۱۲} و همکاران، ۲۰۲۲). داده‌های بارندگی معمولاً در مطالعات تهیه نقشه سیل گنجانده می‌شوند؛ زیرا به‌طور مستقیم با پتانسیل سیل در ارتباط هستند (برا^{۱۳} و همکاران، ۲۰۲۲). شکل (۴چ).

¹ Rahmati

² Mohammadi

³ Gruber & Peckham

⁴ Choubin

⁵ Yousefi

⁶ Lee

⁷ Opperman

⁸ Andaryani

⁹ Ayalew & Krajewski

¹⁰ Komolafe

¹¹ Teegavarapu

¹² Verma

¹³ Bera

کاربری اراضی: کاربری اراضی عاملی است که بر میزان نفوذ و رواناب حاصل از بارندگی موثر است (کازاکیس^۱ و همکاران، ۲۰۱۵). شکل (۴ح).

بافت خاک: نفوذ آب که نقش مهمی در تولید رواناب بارندگی ایفا می‌کند، به‌طور مستقیم توسط خواص خاک تنظیم می‌شود (فیلیپس^۲ و همکاران، ۲۰۱۹) شکل (۴خ).

شاخص قدرت رودخانه: SPI یکی دیگر از پارامترهای مورفومتریک است که برای پیش‌بینی سیل استفاده می‌شود شکل (۴د).

شاخص پوشش گیاهی متفاوت نرمالیزه‌شده (NDVI^۳): NDVI با تصاویر سنتینل ۲ با وضوح مکانی ۱۰ متر با استفاده از باند مادون قرمز نزدیک (NIR- B8) و نوار قرمز (B4) محاسبه شد (آمادیو^۴ و همکاران، ۲۰۱۶؛ فاین^۵ و همکاران، ۲۰۱۷e). پوشش گیاهی نقش بسزایی در بررسی حساسیت به سیل دارد (موهان^۶ و همکاران، ۲۰۱۸). شکل (۴ذ).

شاخص رطوبت توپوگرافی (TWI^۷): شاخص رطوبت توپوگرافی (TWI) معیاری است که برای تعیین کمیت تأثیر توپوگرافی بر فرآیندهای هیدرولوژیکی استفاده می‌شود (پور علی^۸ و همکاران، ۲۰۱۶) و تحت تأثیر تغییرپذیری مکانی رطوبت خاک است (وینزeler^۹ و همکاران، ۲۰۲۲). با استفاده از عامل شیب و انباشت جریان می‌توانید مناطق با پتانسیل سیل‌خیزی بالا را شناسایی نمایید (بویو همکاران، ۲۰۲۰). شکل (۴ر).

شاخص رطوبت متفاوت نرمالیزه‌شده (NDMI^{۱۰}): شاخص رطوبت تفاوت نرمال‌شده توسعه‌یافته توسط ویلسون و سادر (۲۰۰۲)، با هدف جستجوی رطوبت خاک است. به‌طور معمول در مناطق پرآب و غرقاب رطوبت خاک زیاد خواهد بود (ساهو و بنگال^{۱۱}، ۲۰۱۸). برای محاسبه NDMI با استفاده از لندست ۸، فرمول (۱) به شرح زیر است:

$$NDMI = \frac{Band5(Near\ Infrared) - Band6(middle\ Infrared)}{Band5(Near\ Infrared) + Band6(middle\ Infrared)} \quad (1)$$

در NDMI، مقادیر بالا نشان‌دهنده وجود رطوبت بیشتر خاک در زیرتوده‌های آبی عظیم و مقادیر پایین نشان‌دهنده رطوبت کم خاک است. شکل (۴ز).

شاخص ناهمواری توپوگرافی (TRI^{۱۲}): یک عامل کمک‌کننده مهم در تهیه نقشه حساسیت و نشان‌دهنده تغییر ارتفاع در یک منطقه مشخص از زمین است. هرچه مقدار TRI بالاتر باشد، زمین ناهموارتر است (آیدین و ایبان^{۱۳}، ۲۰۲۳). شکل (۴ژ).

¹ Kazakis

² Phillips

³ Normalized difference vegetation index

⁴ Amadio

⁵ Fayne

⁶ Mohajane

⁷ Topographic Wetness Index

⁸ Pourali

⁹ Winzeler

¹⁰ Normalized difference moisture index


¹¹ Sahu & Bengal

¹² Topographic roughness index

¹³ Aydin & Iban


زمین‌شناسی: زمین‌شناسی یکی از عوامل موثر در وقوع سیلاب است که در این مطالعه در نظر گرفته شده است و در مورد منطقه مورد مطالعه اطلاعاتی پیرامون ماهیت سنگ‌شناسی، ساختار منطقه و هندسه آن ارائه می‌دهد (چن و همکاران، ۲۰۱۸). تنوع سنگ‌شناسی می‌تواند میزان آسیب‌پذیری سیل را تقویت یا کاهش دهد (کازاکیس و همکاران، ۲۰۱۵). شکل (۴س).


جهت جریان: یکی دیگر از عوامل مهم هیدرولوژیکی برای ارزیابی سیل است؛ زیرا مسیر جریان را تحت تأثیر قرار می‌دهد و انباشت آب را تعیین می‌کند (خوریونیس^۱ و همکاران، ۲۰۲۱؛ الجویدی^۲ و همکاران، ۲۰۱۸). در این مطالعه، جهت جریان از DEM (12.5 متر) تهیه شد. شکل (۴ش).



¹ Khoirunisa

² Al-Juaidi





در این مطالعه از الگوریتم‌های یادگیری ماشین برای ارزیابی حساسیت سیل استفاده شد. دو مدل، RF و ANN در محیط برنامه نویسی R پیاده‌سازی شد. از بسته‌های موجود و کتابخانه‌های متداول R برای به‌کارگیری مدل‌های یادگیری ماشین، چارچوبی را برای ساخت و ارزیابی این مدل‌ها ارائه کرد.

مدل جنگل تصادفی

جنگل تصادفی یک مدل یادگیری ماشین نسبتاً جدید با سازگاری قوی با مجموعه داده‌ها است که می‌تواند داده‌های گسسته و پیوسته را پردازش کند (یانگ و لی^۱، ۲۰۲۲). مدل RF نسبت به چندخطی بودن حساس نیست و نتایج آن در صورت وجود داده‌های گم‌شده یا نامتعادل نسبتاً ثابت است (چن^۲ و همکاران، ۲۰۲۰؛ یانگ و لی^۳، ۲۰۲۲e) که به‌طور گسترده برای مدل‌سازی حساسیت به سیل استفاده شده است (اسلام و همکاران، ۲۰۲۱).

مدل شبکه عصبی مصنوعی (ANN^۴)

شبکه‌های عصبی مصنوعی یکی از پرکاربردترین و دقیق‌ترین فن‌های یادگیری ماشین است که توانایی بالایی در مدل‌سازی روابط غیرخطی بین متغیر هدف و متغیرهای توضیحی دارند (کیا^۵ و همکاران، ۲۰۱۲) که چندبعدی هستند (کمپولو^۶ و همکاران، ۲۰۰۳). امروزه، شبکه‌های عصبی مصنوعی اغلب برای مدل‌سازی بلایای سیل استفاده می‌شود (ژانگ و چن^۷، ۲۰۱۹).

معیارهای ارزیابی مدل

ارزیابی دقت مدل یک گام مهم در هر فن نقشه‌برداری پیش‌بینی است؛ زیرا اهمیت علمی مدل را مشخص می‌کند. این ارزیابی شامل مقایسه پیش‌بینی مدل‌ها بر روی داده‌های دیده‌نشده (داده‌های آزمایش) با نتایج شناخته‌شده از مجموعه داده آموزشی جداگانه است (چن^۸ و همکاران، ۲۰۲۲). ضریب تعیین (رایت^۹، ۱۹۲۱) را می‌توان به‌عنوان نسبت واریانس در متغیر وابسته که از متغیرهای مستقل قابل‌پیش‌بینی است، تفسیر کرد. مقادیر مثبت ضریب تعیین در بازه [۰، ۱] که ۱ به معنای پیش‌بینی کامل است. مقادیری مانند $R^2 = 0.8$ به وضوح عملکرد بسیار خوب مدل رگرسیون را بدون توجه به محدوده مقادیر حقیقت زمین و توزیع آنها نشان می‌دهد. در این مطالعه، مجموعه داده‌های آموزشی و آزمایشی برای ساخت و اعتبارسنجی مدل‌های حساسیت به سیل استفاده شد. MAE، R-squared یا R^2 و RMSE با استفاده از معادلات زیر برای تعیین دقت پیش‌بینی محاسبه شدند (معادل ۲، ۳، و ۴):

$$MAE = \frac{\sum_{i=1}^n |X_i - Y_i|}{n} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{n}} \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^m (X_i - Y_i)^2}{\sum_{i=1}^m (\bar{Y} - Y_i)^2} \quad (4)$$

به ترتیب برای مقادیر مشاهده‌شده و پیش‌بینی‌شده. در هر موقعیتی، مقادیر بالای R^2 ، کوچک‌ترین مقدار MAE و RMSE نشان‌دهنده برازندگی بیشتر مدل است. تناسب بیشتر مدل همیشه با مقادیر کمتر MAE و RMSE و مقادیر بیشتر R^2 نشان داده می‌شود.

¹ Yang & Li

² Chen

³ Yang & Li

⁴ Artificial Neural Networks (ANN)

⁵ Kia

⁶ Campolo

⁷ Zhang & Chen

⁸ Chen

⁹ Wright


تهیه نقشه‌های آسیب‌پذیری سیل

لایه‌های رستری حساسیت به سیل در RStudio تولیدشده برای نقشه‌برداری وارد محیط GIS شدند. مدل‌های حساسیت به سیل حاصل از الگوریتم‌های RF و ANN، در ابتدا به‌طور پیش‌فرض به یک مقیاس احتمال پیوسته اختصاص داده شدند. برای دقت تفسیر و شناسایی مناطق حساس متمایز، از روش طبقه‌بندی شکست‌های طبیعی استفاده شد. این روش به‌طور موثر داده‌ها را بر اساس توزیع داده‌های طبیعی و همسو با الگوهای فضایی وقوع سیل، طبقه‌بندی کرد. برای تکمیل احتمالات عددی، به هر کلاس یک برچسب کیفی از خیلی کم تا خیلی زیاد در مقیاس طبقه‌بندی اختصاص داده شد. این مبحث، روشی مناسب برای برقراری ارتباط اطلاعات مکانی پیچیده ارائه می‌دهد.

نتایج و بحث

اهمیت نسبی عوامل شرطی برای تهیه نقشه حساسیت سیل

مجموعه مدل‌های مبتنی بر درخت، با در نظر گرفتن اثرات تعاملی بین متغیرهای مستقل و اهمیت نسبی رتبه‌بندی آن‌ها در فرآیند مدل‌سازی، مزیت قابل توجهی ارائه می‌کنند (Mišić, ۲۰۲۰). ۱۶ لایه ورودی به‌عنوان متغیرهای مستقل وارد فرآیند مدل‌سازی شدند. اهمیت تمامی عوامل، تعیین شده و در شکل ۵ نشان داده شده است. ارتباط هر عامل برای هر دو مدل با استفاده از نرم‌افزار R ارزیابی شد. نتایج نشان داد که در هر دو مدل RF و ANN کاربری اراضی به‌عنوان مهم‌ترین عامل شناسایی شد و در مدل RF عوامل انحنا، بافت خاک، تراکم شبکه زهکشی، جهت جریان، زمین‌شناسی، جهت شیب و در مدل ANN عوامل فاصله از رودخانه، جهت جریان، ارتفاع و تراکم شبکه زهکشی و جهت شیب به‌عنوان کم نفوذترین عوامل معرفی شدند. به‌طور کلی، مدل‌ها الگوی مشابهی را در اولویت‌بندی عوامل شرطی‌سازی برای حساسیت به سیل از خود نشان ندادند. این یافته‌ها از پژوهش‌های قبلی حمایت می‌کند که نشان می‌دهد کاربری اراضی عامل مهمی در حساسیت به سیل است (رحیمی و رحیمی داشلی‌برون، ۱۳۹۳؛ رشیدیان، ۱۴۰۱؛ ثقفیان و همکاران، ۱۳۸۵).



شکل ۵: اهمیت نسبی عوامل شرطی‌سازی: (الف) RF. (ب) ANN

معیارهای ارزیابی و اعتبارسنجی مدل

این پژوهش با استفاده از معیارهایی مانند، MAE، Rsquared و RMSE، نتایج مدل را در برابر نقشه موجودی سیل به‌صورت کمی اعتبارسنجی کرد. نقشه‌های حساسیت سیل با استفاده از دو مدل RF و ANN تهیه شد. یافته‌های


MAE، Rsquared و RMSE برای هر دو مدل یادشده نیز در جدول (۳) تجزیه و تحلیل شدند. نتایج به وضوح نشان داد که مدل RF دارای کمترین مقدار MAE که برابر با ۰/۰۸۸۹ و کمترین مقدار RMSE برابر با ۰/۱۸۷۲، بیشترین مقدار R squared که برابر ۰/۸۴۲۳ در مقایسه با مدل ANN عملکرد بهتری داشت جدول (۳). در نتیجه، مدل RF رابطه بسیار خوبی بین نقاط سیل واقعی و نقاط سیلاب پیش‌بینی‌شده در مقایسه با مدل ANN به‌کاررفته در مطالعه داشت. این نشان می‌دهد که مدل‌های RF دارای درجه بسیار بالایی از مقبولیت همراه با نقص‌های کمتر در هنگام مدل‌سازی نقشه حساسیت سیل (FSM) است.

جدول ۳: ارزیابی دقت دو مدل RF و ANN برای داده‌های آموزشی از طریق معیارهای خطای مختلف

مدل	RF	ANN
RMSE	۰,۱۸۷۲	۰,۲۵۹۱
R squared	۰,۸۴۲۳	۰,۷۰۵۶
MAE	۰,۰۸۸۹	۰,۱۶۲۸

تهیه نقشه حساسیت سیل

نقشه‌های حساسیت به سیل برای هر دو مدل RF و ANN تولید شد. نقشه‌ها یک مقیاس احتمال پیوسته از ۰ (کمترین حساسیت) تا ۱ (بالترین حساسیت) را نشان دادند. برای افزایش تفسیرپذیری، نقشه‌ها با استفاده از روش شکست طبیعی به ۳ دسته طبقه‌بندی شدند. این نکته قابل توجه است که محدوده سیلاب برای هر طبقه بین دو مدل متفاوت است. به هر طبقه یک برچسب (حساسیت کم، متوسط، بالا) اختصاص داده شد. شکل ۵ (الف و ب) تجزیه و تحلیل نقشه حساسیت سیل را برای هر دو مدل نشان داد که در مدل RF، بالاترین و کمترین کلاس حساسیت به ترتیب ۱۳/۹٪ و ۶۲/۹٪ از کل مساحت را تشکیل می‌دهند. در حالی که این مقادیر برای مدل ANN ۱۰/۲٪ و ۸۸٪ بود. جدول (۴).



شکل ۵: (الف) نقشه حساسیت سیل با مدل ANN (ب) نقشه حساسیت سیل با مدل RF منبع: نگارندگان

جدول ۴: آماری از حساسیت سیل با مدل RF و ANN

مدل	حساسیت به سیل	مساحت (km^2)	درصد (%)
ANN	بالا	۱۹۵۸/۰۸	۱۰/۲
	متوسط	۳۵۵/۱۵۸	۱/۸
	بدون / پایین	۱۶۹۳۳/۵۳	۸۸
RF	بالا	۲۶۸۷/۹۹	۱۳/۹
	متوسط	۴۴۶۰/۸۲	۲۳/۲
	بدون / پایین	۱۲۰۹۷/۹۸	۶۲/۹

این مطالعه با موفقیت یک چارچوب جامع جهت ارزیابی خطر سیل را برای استان ایلام ارائه می‌کند. در این پژوهش، برای اولین بار با استفاده از مدل‌های یادگیری ماشین، نقشه‌های موثر و قابل اعتماد خطر سیل برای منطقه تهیه شد. این نقشه‌ها بر مؤلفه خطر مدیریت ریسک بلایا تمرکز دارد و احتمال وقوع سیل در سراسر استان ایلام را نشان می‌دهند.

چندین مطالعه، فناوری‌های سنجش‌ازدور را با یادگیری ماشینی ادغام کرده‌اند تا نقشه‌های حساسیت خطر سیل را توسعه دهند. به‌عنوان مثال، حسن الزمان^۱ (۲۰۲۲) از سه مدل یادگیری ماشین گروهی، یعنی جنگل تصادفی (RF)، ساده بیز (NB) و افزایش گرادیان شدید (XG) برای ایجاد نقشه‌های حساسیت به سیل استفاده کرد که عملکرد مدل RF برای FSM بهتر از مدل‌های دیگر بود. سابرو^۲ و همکاران (۲۰۲۳) از سه فن یادگیری ماشین (RF، LightGBM، و CatBoost) برای تهیه نقشه‌های حساسیت به سیل (FSMs) استفاده کردند. ۱۰ تا ۱۳ درصد از کل منطقه به‌شدت مستعد سیل است. همچنین، رن و همکاران (۲۰۲۴) عملکرد مدل‌های یادگیری ماشین را با استفاده از مجموعه داده‌های نامتعادل نقاط سیل و غیر سیل مشتق‌شده از موجودی سیل مبتنی بر ماهواره بررسی کردند. آنها کشف کردند که دقت مدل زمانی به حداکثر می‌رسد که مجموعه داده متعادل باشد و نقاط سیلابی و غیرسیلابی برابری داشته باشد. بر اساس نتایج آنها، این مطالعه مجموعه داده‌ای از ۱۵۰۰ نقطه سیل و غیرسیل را برای آموزش و آزمایش الگوریتم‌های یادگیری ماشین انتخاب کرد. احمد^۳ و همکاران (۲۰۲۵) با استفاده از الگوریتم یادگیری ماشین گروهی، تقویت گرادیان شدید (XGBoost) و جنگل تصادفی (RF) حساسیت سیل بررسی کردند. نزدیکی به رودخانه‌ها و نواحی پست‌تر از عوامل مهم در قوع سیلاب هستند و مدل RF از نظر دقت پیش‌بینی بهتر از XGBoost عمل کرد.

یک محدودیت کلیدی روش‌های موجود برای نقشه‌برداری حساسیت سیل، اتکای آنها به فهرست سیل رویدادهای گذشته است که معمولاً از طریق تصاویر ماهواره‌ای پس از سیل یا بررسی‌های میدانی به‌دست می‌آیند. چنین موجودی‌هایی اغلب نمی‌توانند میزان کامل سیل را در اوج خود ثبت کنند و حداکثر سیل‌های احتمالی آینده (PMF) را در نظر نمی‌گیرند که تحت پیش‌بینی‌های فعلی تغییرات آب‌وهوایی بسیار محتمل است. این پژوهش این شکاف‌ها را با استفاده از پهنه‌بندی مدل Maxent برطرف کرد. نقاط سیل با استفاده از مدل Maxent تهیه شد.

از موجودی سیل به‌دست‌آمده، مجموعه داده‌های آموزشی و آزمایشی ایجاد شد و سپس با استفاده از الگوریتم‌های یادگیری ماشین (ANN و RF)، نقشه‌های حساسیت سیل در استان ایلام تهیه شد. نتایج اعتبارسنجی مدل نشان داد

¹ Hasanuzzaman² Saber³ Ahmad

که RF بهتر از ANN عمل می‌کند. نتایج به وضوح نشان می‌دهد که مدل RF دارای کمترین مقدار MAE برابر ۰/۰۸۸۹، کمترین مقدار RMSE برابر است با ۰/۱۸۷۲ و بالاترین مقدار Rsquared برابر با ۰/۸۴۲۳ در مقایسه با مدل ANN است. یافته‌های این مطالعه با مطالعات قبلی که همچنین دقت بالاتری را برای RF در مقایسه با سایر الگوریتم‌های یادگیری ماشین ثبت کرده‌اند، مطابقت دارد (احمد و همکاران، ۲۰۲۵؛ وی^۱ و همکاران، ۲۰۲۳؛ حسن الزمان^۲، ۲۰۲۲).

مدل RF نشان داد که مساحت ۲۶۸۷،۹۹ کیلومتر مربع از استان ایلام "بسیار" مستعد خطر سیل است، درحالی‌که ۴۴۶۰،۸۲ کیلومتر مربع در محدوده با حساسیت متوسط سیل واقع شده است. مدل ANN، ۱۹۵۸،۰۸ کیلومتر مربع و مساحت ۳۵۵،۱۵۸ کیلومتر مربعی را به‌عنوان مناطق حساس به سیل "بالا" و "متوسط" شناسایی کرد (جدول ۱۳). نتایج نشان داد که بر اساس مدل‌های RF، ANN، به‌ترتیب ۱۳/۹٪، ۱۰/۲٪ از محدوده مورد مطالعه در منطقه حساس به سیل "بالا" قرار دارند. بیشتر مناطق با حساسیت بالا در منطقه ورودی دره‌های مهم استان به دشت‌ها یافت شد. برای دو مدل، یک الگوی توزیع جغرافیایی سازگار از مناطق مستعد سیل با توجه به منطقه شامل گروه‌های «متوسط» و «بالا» مشاهده شد. با این حال، در مدل ANN، آمار طبقه ب «بالا» به‌طور جزئی کمتر از مدل RF است. نتایج نشان داد که شهر بیشتر در مناطق با حساسیت بالا و مناطق مرتفع کوهستانی و تپه‌ای بر مناطق با حساسیت کم و یا بدون خطر سیل واقع شدند.

نتیجه‌گیری

سیل یک بلای طبیعی است که زندگی مردم را تهدید می‌کند، انتظار می‌رود سیل‌ها به‌دلیل تغییرات اقلیمی و کاربری اراضی با تعداد و شدت بیشتر رخ دهند. به همین دلیل، بهبود روش‌های پیش‌بینی و پیشگیری از سیل برای کاهش خطرات جانی و اثرات منفی اجتماعی و اقتصادی سیل‌ها بسیار مهم است. این امر مستلزم رویکردی جدید، قدرتمند و مؤثر برای کاهش آسیب‌های وارده به زندگی و اقتصاد انسان است. این مطالعه با رویکرد از یادگیری ماشین برای پیش‌بینی مناطقی با احتمال وقوع سیل تمرکز دارد.

با توجه به اینکه بخش وسیعی از استان ایلام کوهستانی و دارای ارتفاع بالایی است، در امتداد دره‌های مهم استان سیل رخ داده است. وقتی دره‌ها وارد دشت‌ها می‌شوند، به‌دلیل تغییرات مورفولوژی و باز شدن دشت‌ها، آب از بستر طبیعی رودخانه‌ها خارج شده و وارد پهنه‌های دشتی سیل‌گیر می‌شوند.

مدل‌های جنگل تصادفی (RF) و شبکه عصبی مصنوعی (ANN) با استفاده از یک پایگاه داده فضایی ساخته شده‌اند که داده‌ها شامل ۱۶ عوامل توپوگرافی و ژئومحیطی مؤثر سیل و ۱۰۴۱ وقوع سیل قبلی است. آزمایش‌ها شواهدی مبنی بر چندخطی بودن بین عوامل شرطی‌سازی شناسایی شده نشان نداد. یافته‌های اعتبارسنجی نشان داد که دو مدل استفاده‌شده عملکرد قابل‌توجهی داشتند. با این حال، RF از نظر محاسباتی، دقت پیش‌بینی و سایر معیارهای ارزیابی کارآمدتر از ANN است که با مقدار $R^2 = 0/8423$ نشان داد. زیرا آموزش مدل با RF به زمان اجرای کمتری نیاز دارد. بنابراین، مدل RF ممکن است یک نقشه حساسیت به سیل و یک روش بالقوه برای پیش‌بینی سیل در عصر داده‌های بزرگ به‌دلیل ظرفیت آن برای رسیدگی به انواع مختلف متغیرها ایجاد کند. این یافته‌ها با مطالعات قبلی

¹ Vu

² Hasanuzzaman

مطابقت دارد (احمد و همکاران، ۲۰۲۵؛ وی^۱ و همکاران، ۲۰۲۳؛ حسن الزمان^۲، ۲۰۲۲). و کارایی RF را در مدیریت مجموعه داده‌های متنوع و پیچیده با نیاز به پارامتر کمتر در مقایسه با ANN برجسته می‌کند. شناسایی عوامل کلیدی مانند کاربری اراضی، ارتفاع و شاخص رطوبت توپوگرافی (TWI) درک پویایی سیل را در منطقه مورد مطالعه تقویت کرده است و همچنین نتایج نشان داد که تقریباً ۱۰/۲٪ تا ۱۳/۹٪ از کل منطقه به شدت در برابر سیل آسیب‌پذیر است. نقشه‌های حاصل ممکن است به عنوان مبنایی برای ایجاد طرح‌هایی برای به حداقل رساندن حساسیت سیل عمل کند.

نقشه‌های حساسیت سیل که از طریق این مطالعه ایجاد شده است، اطلاعات مهمی را برای مقامات در جهت توسعه زیرساخت و تیم‌های مدیریت بلایا ارائه می‌دهد. این نقشه‌ها شناسایی مناطق بسیار حساس به سیل را امکان‌پذیر می‌سازد و برنامه‌ریزی و اجرای طرح‌های توسعه متمرکز بر کاهش خطرات سیل را هدایت می‌کند. علاوه بر این، آنها به مقامات برنامه‌ریزی کاربری زمین در انتخاب مکان‌هایی برای توسعه آینده که کمتر مستعد سیل هستند، کمک خواهند کرد. برای مقامات مدیریت بلایا، نقشه‌ها به شناسایی جوامعی که قبلاً در معرض خطر سیل بوده‌اند، کمک می‌کند. به این ترتیب، نقشه‌های حساسیت به سیل به عنوان یک ابزار حیاتی برای تصمیم‌گیری آگاهانه و کاهش خطر سیل استفاده خواهد شد. تحقیقات آینده باید بر ترکیب داده‌های هیدرولوژیکی و آب‌وهوایی زیرحوضه‌های استان در معرض سیل برای افزایش دقت مدل و بررسی پتانسیل الگوریتم‌های پیشرفته یادگیری ماشین برای نقشه‌برداری حساسیت سیل تمرکز کند. این مطالعه، زمینه را برای توسعه روش‌های قوی و مبتنی بر داده‌ها برای مدیریت خطر سیل در مناطق مشابه در مکان دیگر فراهم می‌کند.

منابع

- ثقفیان، بهرام؛ فرازجو، حسن؛ سپهری، عادل؛ نجفی‌نژاد، علی. (۱۳۸۵). بررسی اثر تغییرات کاربری اراضی بر سیل خیزی حوزه آبریز سد گلستان، تحقیقات منابع آب ایران، سال دوم، ش ۱، صص: ۲۸-۱۸.
- رحیمی، داریوش؛ رحیمی داشلی‌برون، یونس. (۱۳۹۳). بررسی تغییرات اقلیم و کاربری اراضی بر سیلاب در شمال ایران (حوضه مادرسو)، جغرافیا و برنامه‌ریزی محیطی، سال ۲۷، ش ۱، صص: ۸۹-۱۰۲.
- رشیدیان، مجتبی. (۱۴۰۱). ارزیابی اثرات تغییر کاربری حال و آینده بر روی ریسک سیلاب، پایان نامه کارشناسی ارشد، دانشکده مهندسی عمران، دانشگاه خواجه نصیرالدین طوسی.
- سلامتی هرمزی، وحید؛ امیدوار، کمال؛ کاوسی، رضا؛ حمزه نژاد. مجتبی. (۱۳۹۶). شناسایی و تحلیل همدیدی - دینامیکی الگوهای جوی سیلاب آبان ۱۳۹۴ در استان‌های ایلام و لرستان. نیوار، دوره ۴۱، ش (۹۶-۹۷)، صص: ۲۷-۹.
- طهماسبی، قباد. (۱۴۰۰). مدیریت بحران مخاطرات شهری با تأکید بر خطر وقوع سیل (مطالعه موردی: شهر ایلام)، پایان‌نامه دکتری، دانشکده علوم اجتماعی، دانشگاه محقق اردبیلی.
- عباس‌زاده تهرانی، نادیا؛ مخدوم فرخنده، مجید؛ مهدوی، محمد. (۱۳۸۹). بررسی تأثیر تغییرات کاربری اراضی بر میزان دبی سیلاب‌ها با کاربرد فناوری سنجش‌ازدور و سامانه اطلاعات جغرافیایی (GIS) (منطقه مورد مطالعه: حوزه آبریز رودخانه مادرسو (پارک ملی گلستان))، پژوهش‌های محیط زیست، دوره ۱، ش ۲، صص: ۱۴-۱.
- لاهوئی نسب، سیده فائز؛ قاسمیه، هدی. (۱۴۰۳). کاربرد DEMATEL-AHP و SVM در شناسایی مناطق مستعد سیلاب (مطالعه موردی: حوزه آبخیز بزرگ کاشان). تحقیقات آب و خاک ایران، دوره ۵۵، ش ۱۰، صص: ۱۹۶۰-۱۹۳۹.

¹ Vu

² Hasanuzzaman

- نیک‌پور، نورالله؛ ثروتی، محمدرضا؛ حسین‌زاده، محمدمهدی؛ ده‌بزرگی، مریم. (۱۳۹۳). بررسی ژئومورفولوژی (مورفوتکتونیک) بخش میانی تاقدیس کبیر کوه واقع در استان ایلام (از پشته اریشت تا امام زاده شاه محمد کوه نشین)، پایان‌نامه کارشناسی ارشد، دانشگاه شهید بهشتی.
- Adeyemi, A. B., & Komolafe, A. A. (2025). Flood hazard zones prediction using machine-learning-based geospatial approach in the lower Niger River basin, Nigeria. *Natural Hazards Research*, 5(2), 399–412. <https://doi.org/10.1016/j.nhres.2025.01.002>
- Ahmad, I., Farooq, R., Ashraf, M. *et al.* Improving flood hazard susceptibility assessment by integrating hydrodynamic modeling with remote sensing and ensemble machine learning. *Nat Hazards* 121, 7839–7868 (2025). <https://doi.org/10.1007/s11069-025-07109-2>
- Ahmed, I. A., Talukdar, S., Shahfahad, Parvez, A. *et al.* (2022). Flood susceptibility modeling in the urban watershed of Guwahati using improved metaheuristic-based ensemble machine learning algorithms. *Geocarto International*, 37(26), 12238-12266.
- Al-Juaidi, A. E., Nassar, A. M., & Al-Juaidi, O. E. (2018). Evaluation of flood susceptibility mapping using logistic regression and GIS conditioning factors. *Arab J Geosci*, 11(24), 765. <https://doi.org/10.1007/s12517-018-4095-0>
- Amadio, M., Mysiak, J., Carrera, L., & Koks, E. (2016). Improving flood damage assessment models in Italy. *Natural Hazards*, 82, 2075-2088. DOI 10.1007/s11069-016-2286-0
- Andaryani, S., Nourani, V., Haghighi, A. T., & Keesstra, S. (2021). Integration of hard and soft supervised machine learning for flood susceptibility mapping. *Journal of Environmental Management*, 291, 112731. <https://doi.org/10.1016/j.jenvman.2021.112731>
- Arora, A., Arabameri, A., Pandey, M. *et al.* (2021). Optimization of state-of-the-art fuzzy-metaheuristic ANFIS-based machine learning models for flood susceptibility prediction mapping in the Middle Ganga Plain, India. *Science of the Total Environment*, 750, 141565. <https://doi.org/10.1016/j.scitotenv.2020.141565>
- Ayalew, T. B., & Krajewski, W. F. (2017). Effect of river network geometry on flood frequency: a tale of two watersheds in Iowa. *Journal of Hydrologic Engineering*, 22(8), 06017004.
- Aydin, H. E., & Iban, M. C. (2023). Predicting and analyzing flood susceptibility using boosting-based ensemble machine learning algorithms with Shapley Additive exPlanations. *Natural Hazards*, 116(3), 2957-2991.
- Band, S. S., Janizadeh, S., Chandra Pal, S., *et al.* (2020). Flash flood susceptibility modeling using new approaches of hybrid and ensemble tree-based machine learning algorithms. *Remote Sensing*, 12(21), 3568.
- Benkirane, M., Laftouhi, N. E., El Mansouri, B. *et al.*, ... & Zamrane, Z. (2020). An approach for flood assessment by numerical modeling of extreme hydrological events in the Zat watershed (High Atlas, Morocco). *Urban Water Journal*, 17(5), 381-389.
- Bera, A., Meraj, G., Kanga, S., *et al.* (2022). Vulnerability and risk assessment to climate change in Sagar Island, India. *Water*, 14(5), 823.
- Bui, D. T., Pradhan, B., Nampak, H., *et al.* (2016). Hybrid artificial intelligence approach based on a neural fuzzy inference model and metaheuristic optimization for flood susceptibility modeling in a high-frequency tropical cyclone area using GIS. *Journal of Hydrology*, 540, 317-330. <https://doi.org/10.1016/j.jhydrol.2016.06.027>
- Bui, Q. T., Nguyen, Q. H., Nguyen, X. L., *et al.* (2020). Verification of novel integrations of swarm intelligence algorithms into deep learning neural networks for flood susceptibility mapping. *Journal of Hydrology*, 581, 124379. <https://doi.org/10.1016/j.jhydrol.2019.124379>
- Campolo, M., Soldati, A., & Andreussi, P. (2003). Artificial neural network approach to flood forecasting in the River Arno. *Hydrological Sciences Journal*, 48(3), 381-398.
- Chen, S., Arrouays, D., Mulder, V. L., *et al.* & Walter, C. (2022). Digital mapping of GlobalSoilMap soil properties at a broad scale: A review. *Geoderma*, 409, 115567. <https://doi.org/10.1016/j.geoderma.2021.115567>
- Chen, W., Li, Y., Xue, W., *et al.* (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>
- Chen, W., Pourghasemi, H. R., & Naghibi, S. A. (2018). A comparative study of landslide susceptibility maps produced using support vector machine with different kernel functions and entropy data mining models in China. *Bulletin of Engineering Geology and the Environment*, 77, 647-664. <https://doi.org/10.1007/s10064-017-1010-y>
- Choubin, B., Moradi, E., Golshan, M., *et al.* (2019). An ensemble prediction of flood susceptibility using multivariate discriminant analysis, classification and regression trees, and support vector machines. *Science of the Total Environment*, 651, 2087-2096. <https://doi.org/10.1016/j.scitotenv.2018.10.064>
- Costache, R., Pham, Q. B., Arabameri, A., *et al.* (2022). Flash-flood propagation susceptibility estimation using weights of evidence and their novel ensembles with multicriteria decision making and machine learning. *Geocarto International*, 37(25), 8361-8393.

- Debnath, J., Sahariah, D., Nath, N., *et al.* (2024). Modelling on assessment of flood risk susceptibility at the Jia Bharali River basin in Eastern Himalayas by integrating multicollinearity tests and geospatial techniques. *Modeling Earth Systems and Environment*, 10(2), 2393-2419.
- Desai, B., Maskrey, A., Peduzzi, P., *et al.* (2015). Making development sustainable: the future of disaster risk management, global assessment report on disaster risk reduction (UNISDR).
- Dou, J., Yamagishi, H., Pourghasemi, H. R., *et al.* (2015). An integrated artificial neural network model for the landslide susceptibility assessment of Osado Island, Japan. *Natural Hazards*, 78, 1749-1776. <https://doi.org/10.1007/s11069-015-1799-2>
- Duque, E. L., & Aquino, P. T. (2020). Anthropometric analysis in automotive manual transmission gearshift quality perception. In CTI SYMPOSIUM 2018: 17th International Congress and Expo 3-6 December 2018, Berlin, Germany (pp. 97-109). *Springer Berlin Heidelberg*.
- Fayne, J. V., Bolten, J. D., Doyle, C. S., *et al.* (2017). Flood mapping in the lower Mekong River Basin using daily MODIS observations. *International journal of remote sensing*, 38(6), 1737-1757.
- Gruber, S., & Peckham, S. (2009). Land-surface parameters and objects in hydrology. *Developments in soil science*, 33, 171-194. [https://doi.org/10.1016/S0166-2481\(08\)00007-2](https://doi.org/10.1016/S0166-2481(08)00007-2)
- 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, Parts A/B/C*, 127, 103198. <https://doi.org/10.1016/j.pce.2022.103198>
- Islam, A. R. M. T., Talukdar, S., Mahato, S., *et al.* (2021). Flood susceptibility modelling using advanced ensemble machine learning models. *Geoscience Frontiers*, 12(3), 101075.
- Kazakis, N., Kougias, I., & Patsialis, T. (2015). Assessment of flood hazard areas at a regional scale using an index-based approach and Analytical Hierarchy Process: Application in Rhodope-Evros region, Greece. *Science of the Total Environment*, 538, 555-563. <https://doi.org/10.1016/j.scitotenv.2015.08.055>
- Khoirunisa, N., Ku, C. Y., & Liu, C. Y. (2021). A GIS-based artificial neural network model for flood susceptibility assessment. *International Journal of Environmental Research and Public Health*, 18(3), 1072.
- Khosravi, K., Pham, B. T., Chapi, K., *et al.* (2018). A comparative assessment of decision tree algorithms for flash flood susceptibility modeling at Haraz watershed, northern Iran. *Science of the Total Environment*, 627, 744-755. <https://doi.org/10.1016/j.scitotenv.2018.01.266>
- Kia, M. B., Pirasteh, S., Pradhan, B. *et al.* (2012). An artificial neural network model for flood simulation using GIS: Johor River Basin, Malaysia. *Environmental Earth Sciences*, 67, 251-264. <https://doi.org/10.1007/s12665-011-1504-z>
- Komolafe, A. A., Herath, S., & Avtar, R. (2018). Methodology to assess potential flood damages in urban areas under the influence of climate change. *Natural Hazards Review*, 19(2), 05018001. [https://doi.org/10.1061/\(ASCE\)NH.1527-6996.0000278](https://doi.org/10.1061/(ASCE)NH.1527-6996.0000278)
- Kumar, A., Houze, R. A., Rasmussen, K. L., & Peters-Lidard, C. (2014). Simulation of a flash flooding storm at the steep edge of the Himalayas. *Journal of Hydrometeorology*, 15(1), 212-228.
- Lee, M. J., Kang, J. E., & Jeon, S. (2012a, July). Application of frequency ratio model and validation for predictive flooded area susceptibility mapping using GIS. In 2012, *IEEE International Geoscience and Remote Sensing Symposium* (pp. 895-898). IEEE DOI: [10.1109/IGARSS.2012.6351414](https://doi.org/10.1109/IGARSS.2012.6351414)
- Liu, J., Wang, J., Xiong, J., *et al.* (2021). Hybrid models incorporating bivariate statistics and machine learning methods for flash flood susceptibility assessment based on remote sensing datasets. *Remote Sensing*, 13(23), 4945. DOI: [10.3390/rs13234945](https://doi.org/10.3390/rs13234945)
- Mahmood, S. H. (2024). Estimating Models and Evaluating their Efficiency under Multicollinearity in Multiple Linear Regression: A Comparative Study. *Zanco Journal of Human Sciences*, 28(5), 264-277.
- Mateo-Garcia, G., Veitch-Michaelis, J., Smith, L., *et al.* (2021). Towards global flood mapping onboard low-cost satellites with machine learning. *Scientific reports*, 11(1), 7249.
- Merz, B., Kreibich, H., Schwarze, R., & Thieken, A. (2010). Review article" Assessment of economic flood damage". *Natural Hazards and Earth System Sciences*, 10(8), 1697-1724.
- Mishra, A., Mukherjee, S., Merz, B., Singh, V. P., Wright, D. B., Villarini, G., ... & Stedinger, J. R. (2022). An overview of flood concepts, challenges, and future directions. *Journal of Hydrologic Engineering*, 27(6), 03122001.
- Mišić, V. V. (2020). Optimization of tree ensembles. *Operations Research*, 68(5), 1605-1624.
- Mohajane, M., Essahlaoui, A. L. I., Oudija, F., *et al.* (2018). Land use/land cover (LULC) using Landsat data series (MSS, TM, ETM+, and OLI) in Azrou Forest, in the Central Middle Atlas of Morocco. *Environments*, 5(12), 131.

- Mohammadi, A., Kamran, K. V., Karimzadeh, S., *et al.* (2020). Flood detection and susceptibility mapping using Sentinel-1 time series, alternating decision trees, and bag-adtree models. *Complexity*, 2020, 1-21. <https://doi.org/10.1155/2020/4271376>
- Mojaddadi, H., Pradhan, B., Nampak, H., Ahmad, N., & Ghazali, A. H. B. (2017). Ensemble machine-learning-based geospatial approach for flood risk assessment using multi-sensor remote-sensing data and GIS. *Geomatics, Natural Hazards and Risk*, 8(2), 1080-1102.
- Nevo, S., Morin, E., Gerzi Rosenthal, A., *et al.* (2022). Flood forecasting with machine learning models in an operational framework. *Hydrology and Earth System Sciences*, 26(15), 4013-4032.
- Opperman, J. J., Galloway, G. E., Fargione, J., *et al.* (2009). Sustainable floodplains through large-scale reconnection to rivers. *Science*, 326(5959), 1487-1488.
- Phillips, T. H., Baker, M. E., Lautar, K., *et al.* (2019). The capacity of urban forest patches to infiltrate stormwater is influenced by soil physical properties and soil moisture. *Journal of Environmental Management*, 246, 11-18. <https://doi.org/10.1016/j.jenvman.2019.05.127>
- Plate, E. J. (2002). Flood risk and flood management. *Journal of Hydrology*, 267(1-2), 2-11.
- Pourali, S. H., Arrowsmith, C., Chrisman, N., *et al.* (2016). Topography wetness index application in flood-risk-based land use planning. *Applied Spatial Analysis and Policy*, 9, 39-54. <https://doi.org/10.1007/s12061-014-9130-2>
- Rahman, M., Ningsheng, C., Mahmud, G. I., *et al.* (2021). Flooding and its relationship with land cover change, population growth, and road density. *Geoscience Frontiers*, 12(6), 101224.
- Rahmati, O., Falah, F., Naghibi, S. A., *et al.* (2019). Land subsidence modelling using tree-based machine learning algorithms. *Science of the total environment*, 672, 239-252. <https://doi.org/10.1016/j.scitotenv.2019.03.496>
- Ren, H., Pang, B., Bai, P., *et al.* (2024). Flood susceptibility assessment with random sampling strategy in ensemble learning (RF and XGBoost). *Remote Sensing*, 16(2), 320.
- Saber, M., Boulmaiz, T., Guermoui, M., *et al.* (2023). Enhancing flood risk assessment through integration of ensemble learning approaches and physically-based hydrological modeling. *Geomatics, Natural Hazards and Risk*, 14(1), 2203798.
- Sahu, A. S., & Bengal, N. W. (2018). Detection of water-logged areas using geoinformatics techniques and relationship study in Panskura-Tamluk flood plain (India). *Trans. Inst. Indian Geographers*, 40(1), 9-24.
- Salvati, A., Nia, A. M., Salajegheh, A., *et al.* (2023). Flood susceptibility mapping using support vector regression and hyper-parameter optimization. *Journal of Flood Risk Management*, e12920. <https://doi.org/10.1111/jfr3.12920>
- Sarkar, D., & Mondal, P. (2020). Flood vulnerability mapping using frequency ratio (FR) model: a case study on Kulik river basin, Indo-Bangladesh Barind region. *Applied Water Science*, 10(1), 1-13.
- Seydi, S. T., Kanani-Sadat, Y., Hasanlou, M., *et al.* (2022). Comparison of Machine Learning Algorithms for Flood Susceptibility Mapping. *Remote Sensing*, 15(1), 192.
- Shirani, K., & Zakerinejad, R. (2021). Watershed prioritization for the identification of spatial hotspots of flood risk using the combined TOPSIS-GIS-based approach: a case study of the Jarahi-Zohre catchment in Southwest Iran. *AUC GEOGRAPHICA*, 56(1), 120-128.
- Sugianto, S., Deli, A., Miswar, E., *et al.* (2022). The Effect of Land Use and Land Cover Changes on Flood Occurrence in Teunom Watershed, Aceh Jaya. *Land*, 11(8), 1271.
- Teegavarapu, R. S. (2012). *Floods in a changing climate: Extreme precipitation*. Cambridge University Press.
- Tripathi, P. (2015). Flood disaster in India: an analysis of trend and preparedness. *Interdisciplinary Journal of Contemporary Research*, 2(4), 91-98.
- Uddin, K., Gurung, D. R., Giriraj, A., & Shrestha, B. (2013). Application of remote sensing and GIS for flood hazard management: a case study from Sindh Province, Pakistan. *American Journal of Geographic Information Systems*, 2(1), 1-5.
- Verma, S., Bhatla, R., Shahi, N. K., & Mall, R. K. (2022). Regional modulating behavior of Indian summer monsoon rainfall in context of spatio-temporal variation of drought and flood events. *Atmospheric Research*, 274, 106201. <https://doi.org/10.1016/j.atmosres.2022.106201>
- Vu, V. T., Nguyen, H. D., Vu, P. L., *et al.* (2023). Predicting land use effects on flood susceptibility using machine learning and remote sensing in coastal Vietnam. *Water Practice and Technology*. <https://doi.org/10.2166/wpt.2023.088>
- Wang, Y., Fang, Z., Hong, H., & Peng, L. (2020). Flood susceptibility mapping using convolutional neural network frameworks. *Journal of Hydrology*, 582, 124482.
- Wang, Y., Fang, Z., Hong, H., *et al.* (2021). Flood susceptibility mapping by integrating frequency ratio and index of entropy with multilayer perceptron and classification and regression tree. *Journal of Environmental Management*, 289, 112449. <https://doi.org/10.1016/j.jhydrol.2019.124482>
- Wang, Y., Li, Z., Tang, Z., & Zeng, G. (2011). A GIS-based spatial multi-criteria approach for flood risk assessment in the Dongting Lake Region, Hunan, Central China. *Water resources management*, 25, 3465-3484. <https://doi.org/10.1016/j.jenvman.2021.112449>

- Wang, Y., Zhang, P., Xie, Y., *et al.* (2025). Toward explainable flood risk prediction: Integrating a novel hybrid machine learning model. *Sustainable Cities and Society*, 120, 106140. <https://doi.org/10.1016/j.scs.2025.106140>
- Winzeler, H. E., Owens, P. R., Read, Q. D., *et al.* (2022). Topographic wetness index as a proxy for soil moisture in a hillslope catena: flow algorithms and map generalization. *Land*, 11(11), 2018.
- Wright, S. (1921). Correlation and causation. *Journal of agricultural research*, 20(7), 557.
- Xie, K., Ozbay, K., Zhu, Y., & Yang, H. (2017). Evacuation zone modeling under climate change: A data-driven method. *Journal of Infrastructure Systems*, 23(4), 04017013.
- Yang, Y., & Li, X. (2022). Automatic Correction of Parameters of Rice Phenology Prediction Model Based on Random Forest Algorithm. *Procedia Computer Science*, 208, 435-441. <https://doi.org/10.1016/j.procs.2022.10.061>
- Yousefi, S., Pourghasemi, H. R., Emami, S. N., *et al.* (2020). A machine learning framework for multi-hazard modeling and mapping in a mountainous area. *Scientific Reports*, 10(1), 12144.
- Zanchetta, A. D., & Coulibaly, P. (2020). Recent advances in real-time pluvial flash flood forecasting. *Water*, 12(2), 570.
- Zhang, J., & Chen, Y. (2019). Risk assessment of flood disaster induced by typhoon rainstorms in Guangdong province, China. *Sustainability*, 11(10), 2738.
- Zhang, M., Fu, X., Liu, S., & Zhang, C. (2025). Integrating Remote Sensing and Machine Learning for Actionable Flood Risk Assessment: Multi-Scenario Projection in the Ili River Basin in China Under Climate Change. *Remote Sensing*, 17(7), 1189.