

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

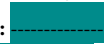
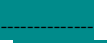
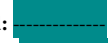

1. PhD Student, Department of Physical Geography, Faculty of Geographical Sciences and Planning, University of Isfahan, Iran.

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. Zakerinejad, Assistant Professor of GIS and RS, Faculty of Geographical Sciences and Planning, University of Isfahan, Iran

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

Article Info	ABSTRACT
<p>Article type: Research Article</p> <p>Article history: Received:  Revised:  Accepted:  Published: </p> <p>Keywords: Machine Learning, Flood Sensitivity Map, Random Forest, Artificial Neural Network, Ilam Province.</p>	<p>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.</p>

How to Cite: Last Name, Initial., Last Name, Initial., & Last Name, Initial. (2021). Title of paper. *Journal of Natural Environmental Hazards*, -- (--), ----.



© The Author/Authors

Publisher: University of Sistan and Baluchestan

DOI: 000000000000000000

این نسخه موقت و قبل از چاپ نهایی می‌باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

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 (Salamati 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.

این نسخه موقت و قبل از چاپ نهایی می باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

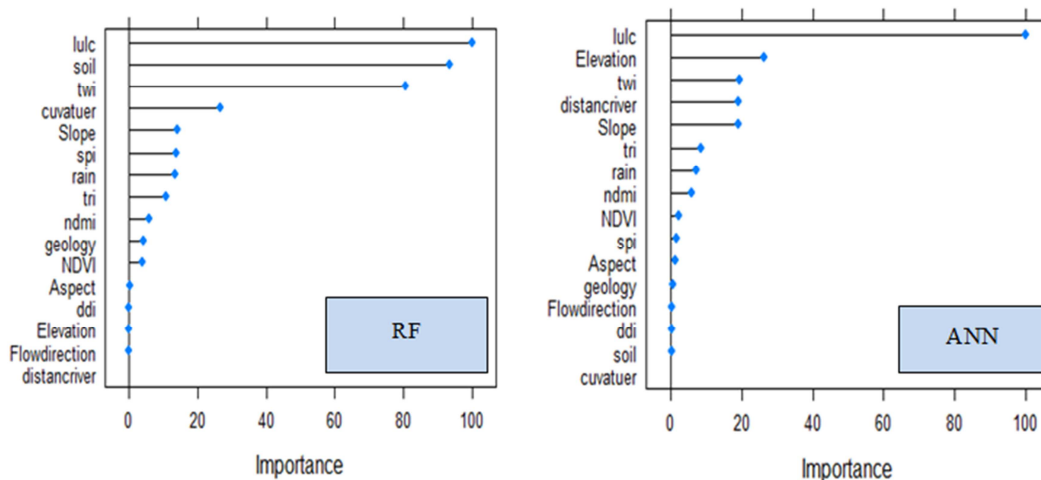


Figure 1: Relative importance of conditioning factors: (a) RF. (b) ANN Source: Authors

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 (km ²)	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., & Thielen, 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.

ساز (بدون شماره مجله)

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 برنامه ریزی، دانشگاه اصفهان، اصفهان

۲. استاد گروه جغرافیای طبیعی، دانشکده علوم جغرافیایی و برنامه ریزی، 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 برنامه ریزی دانشگاه اصفهان

۴. استاد هیدروژئولوژی، دانشکده کشاورزی، دانشگاه ایلام، ایلام

اطلاعات مقاله	چکیده
<p>نوع مقاله: مقاله پژوهشی</p> <p>تاریخ دریافت: /-/</p> <p>تاریخ ویرایش: /-/</p> <p>تاریخ پذیرش: /-/</p> <p>تاریخ انتشار: /-/</p> <p>واژه‌های کلیدی: یادگیری ماشین، نقشه حساسیت سیل، جنگل تصادفی، شبکه عصبی مصنوعی، استان ایلام.</p>	<p>سیل یکی از مخاطرات طبیعی فاجعه بار 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 بلاها 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 بکارگیری مدل‌های یادگیری ماشین (MLM) و تکنیک‌های 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 طبقه بندی 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 اعتبار سنجی استفاده شدند. همچنین نتایج نرخ خطای الگوریتم‌های پیشنهادی در نظر گرفته شد، به وضوح نشان داد که در مدل RF، MAE که برابر با ۰/۸۸۹ و RMSE برابر با ۰/۱۸۲۲ دارای کمترین مقدار، R2 که برابر با ۰/۸۴۲۳ بیشترین مقدار که در مقایسه با مدل ANN عملکرد بهتری داشت. ارزش تحقیق 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.</p>

استناد: نام خانوادگی، نام؛ نام خانوادگی، نام؛ و نام خانوادگی، نام (۱۴۰۰). عنوان مقاله. مخاطرات محیط طبیعی، -- (--) .----

این نسخه موقت و قبل از چاپ نهایی می‌باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

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 مخرب‌ترین، شایع‌ترین (میشرا^۴ و همکاران، ۲۰۲۲) و پرهزینه‌ترین بلاهای طبیعی در جهان است (تریپاتی^۵، ۲۰۱۵، آرورا^۶ و همکاران، ۲۰۲۱) و هر ساله خسارات شدیدی به زیرساخت‌ها در سراسر جهان وارد می‌کند و همچنین موجب تضعیف اقتصاد در سطح کلان می‌گردد (دسای^۷ و همکاران، ۲۰۱۵). بر اساس داده‌های آماری پایگاه داده رویدادهای اضطراری (EM-DAT) در سال ۲۰۲۱، حدود ۱۷۵۰۰۰ مرگ‌ومیر 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 استراتژی‌های بین‌المللی کاهش بلایا (UNISDR) در سال ۲۰۱۵، سیل هر ساله باعث ایجاد حدود ۳۰ میلیارد دلار خسارت به آمریکا وارد می‌کند، همچنین عاملی مؤثر بر تغییرات جمعیتی محسوب می‌شود (نو^۸ و همکاران، ۲۰۲۲). سیل بر اثر عوامل و دلایل طبیعی و انسانی رخ می‌دهد (چانگ و چن^۹، ۲۰۱۶). علاوه بر رویدادهای شدید آب و هوایی ناشی از تغییرات اقلیمی، فعالیت‌های انسانی سهم زیادی در بروز سیل‌های شدید مکرر دارند. فعالیت‌های انسانی، مانند تغییر سریع پوشش زمین، رشد جمعیت و ساخت جاده، سطوح غیرقابل نفوذ را افزایش داده و منجر به سیل‌های رایج و شدیدتر می‌شود (رحمان^{۱۰} و همکاران، ۲۰۲۱). اخیراً دخالت انسان در محیط‌زیست باعث وقوع سیلاب شده است که این سیلاب‌ها بیش از قبل رخ می‌دهد و اساساً به دلیل تخریب محیط‌زیست در مقیاس وسیع به واسطه رشد جمعیت، تجاوز به دشت‌های سیلابی کنار رودخانه، شهرنشینی، جنگل‌زدایی و غیره است (باند^{۱۱} و همکاران، ۲۰۲۰). گاهی از پدیده سیل و پیامدهای آن برای کنترل سیل، کاهش خطر و به طور کلی مدیریت سیل بسیار مهم است. همچنین پیش‌بینی سیل جهت پیش‌بینی 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 تصمیم‌گیری مدیریت ریسک را تسهیل می‌کند و به اجرای استراتژی‌های کاهش سیل کمک می‌کند و راهنمایی برای توسعه پوشش زمین، استفاده از زمین در مناطق آسیب‌پذیر سیل ارائه می‌کند (وانگ^{۱۳} و همکاران، ۲۰۲۰). بخش مهمی از مدیریت ریسک بلایا، ترسیم حساسیت به سیل است که به دولت‌ها و جوامع در پیش‌بینی، واکنش و کاهش اثرات مخرب حوادث سیل کمک می‌کند. فراوانی و شدت سیل در حال افزایش می‌باشد و توسعه مدیریت مؤثر در زمینه سیل را ضروری می‌نماید (کومار^{۱۴} و همکاران، ۲۰۱۴). مدل‌های پیش‌بینی سیل

¹ Uddin

² Wang

³ Zanchetta & Coulibaly

⁴ Mishra

⁵ Tripathi

⁶ Arora

⁷ Desai

⁸ Nevo

⁹ Chang & Chen

¹⁰ Rahman

¹¹ Band

¹² Merz

¹³ Wang

¹⁴ Kumar

این نسخه موقت و قبل از چاپ نهایی می‌باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

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، متنو گارسیا^۲ و همکاران، ۲۰۲۱)؛ بنابراین، انجام تحقیقات در رابطه با 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 مناطق 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 تحقیقی، میزان دبی سیلاب‌های حوضه آبریز رودخانه مادرسو (دوغ) از طریق به کارگیری RS و GIS بررسی کردند. نتایج نشان داد تغییرات کاربری اراضی بر کاهش میزان سیلاب منطقه تاثیر گذار بوده است. طهماسبی (۱۴۰۰) با استفاده از روش‌های کمی و به کمک نرم‌افزار Arc GIS، Envi، Fragtats و روش‌های کیفی و تکنیک‌های 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^۳ نسبی و قاسمیه (۱۴۰۳) با استفاده از مدل‌های DEMATEL-AHP و SVM سیل‌خیزی حوضه آبخیز بزرگ 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. سگیان^۴ و همکاران (۲۰۲۰) به شناسایی مناطق آسیب‌پذیر سیل و ارزیابی علل سیل در حوضه آبخیز تویونوم^۵، آنچه جایا^۶ پرداختند. نتایج نشان داد افزایش چشمگیری در استفاده از زمین‌های مسکونی^۷ زمین‌های بایر، مزارع برنج و تالابها (آب‌ها) داشته است و نفوذناپذیری و اشباح باعث افزایش خطرات سیل منطقه شده است.

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

این نسخه موقت و قبل از چاپ نهایی می‌باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

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 تکنیک یادگیری ماشین (RF، LightGBM، 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 سلسله مراتبی مبتنی بر تصمیم‌گیری چند معیاره و فرآیند تحلیل سلسله مراتبی فازی حساسیت سیل در حوضه آبریز جیا بهارالی^۸ بررسی شد. نتایج نشان داد که حدود یک سوم از حوضه مذکور در مناطق سیل‌خیز متوسط تا بسیار زیاد قرار دارد (دبنا^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، به ویژه 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 عمدتاً 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، در حالی که 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 گرادیان شدید^{۱۹} بررسی شد

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)

این نسخه موقت و قبل از چاپ نهایی می‌باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

نتایج نشان داد 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 شده، که 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، اواخر سال ۱۳۹۸ جان چندین نفر را گرفت (سلامتی هرمزی و همکاران، ۱۳۹۶).

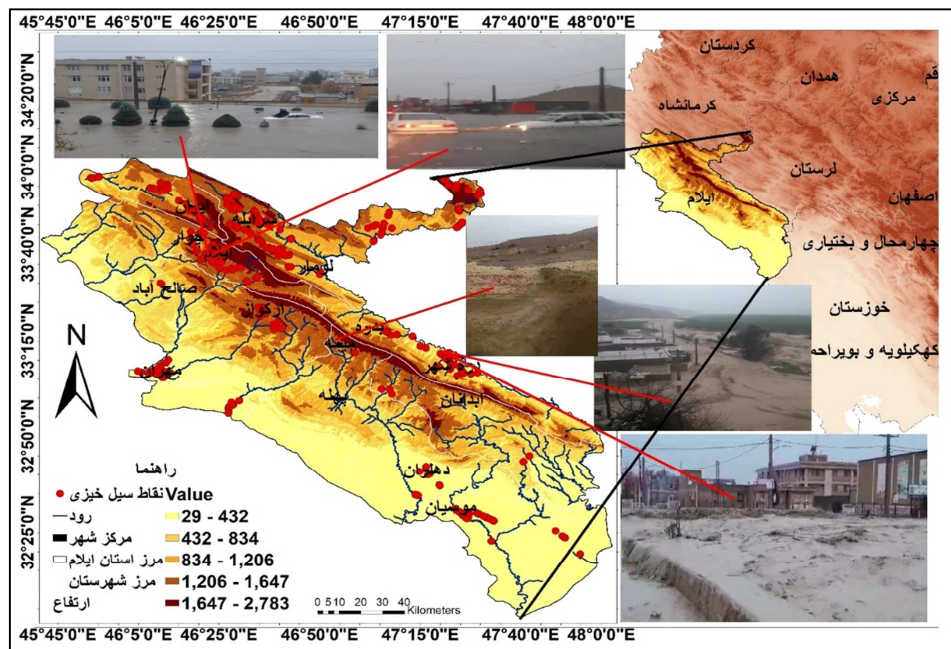
داده‌ها و روش‌ها

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 آب و هوای خشک و نیمه خشک می‌باشد. به طور کلی استان ایلام به لحاظ واحدهای ژئومورفولوژیکی به دو واحد کوهستان (شامل تاقدیس‌های کبیرکوه، دینارکوه، مانشت، قارنگ 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، دوبرج، چنگوله، آبدانان، چناره، میمه و سیاه گاو... 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 خسارات شدیدی به جان انسان‌ها و زیر بناها وارد کرده است.

¹ Zhang

این نسخه موقت و قبل از چاپ نهایی می باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.



شکل ۱: منطقه مورد مطالعه. منبع: نگارندگان

روش‌شناسی

روش‌شناسی شامل سازماندهی کلی تحقیق حاضر است که شامل ایجاد نقشه موجودی سیل، شناسایی متغیرهای موثر بر سیل و تشخیص چند خطی، اعتبارسنجی و تحلیل دقت یا ارزیابی نقشه‌های حساسیت به سیل و غیره است. جدول (۱). مدل‌های به کار برده شده 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 به عنوان متغیرهای ورودی مهم برای محاسبه حساسیت سیل عمل می‌کند (کاستاچ^۱ و همکاران، ۲۰۲۲). تولید نقشه فهرست موجودی سیل (FIM) به طور کلی، از داده‌های سیل قبلی یک منطقه ساخته شده است (احمد^۲ و همکاران، ۲۰۲۲) مدیریت سیل به طور 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 بازیابی به‌طور مؤثر برای کاهش تأثیر سیل انجام شده است (پلات^۳، ۲۰۰۲). نقشه برداری 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 به عنوان یک جزء حیاتی عمل می‌کنند (اسلام^۴ و همکاران، ۲۰۲۱، مجددی^۱ و همکاران، ۲۰۱۷).

¹ Costache

² Ahmed

³ Plate

⁴ Islam

این نسخه موقت و قبل از چاپ نهایی می‌باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

صحت رخدادهای گذشته سیل، دقت و قابلیت اطمینان آسیب پذیری سیل در آینده را تعیین می‌کند (سارکار و موندال^۲، ۲۰۲۰) نتایج پیش‌بینی یادگیری ماشین و مدل‌سازی آماری به‌طور قابل‌توجهی تحت تأثیر دقت داده‌های مکان سیل تاریخی قرار می‌گیرد (لیو^۳ 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^۴ و همکاران، ۲۰۲۰). با توجه به توپوگرافی و کوهستانی بودن منطقه و همچنین نبود تصاویر ماهواره‌ای سنتینل ۱ در زمان وقوع سیل در منطقه نرم افزار گوگل ارث انجین^۵ (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^۶ برای تهیه نقشه موجودی سیل گرفته شد. این سیلاب‌ها به دو گروه تقسیم شدند. گروه اول شامل ۷۰ درصد از داده‌های سیل بود به عنوان مجموعه داده آموزشی استفاده شد و گروه دوم شامل ۳۰ درصد از داده‌های باقی مانده بود که به عنوان مجموعه داده اعتبار سنجی استفاده شد. علاوه بر این، ۶۱۷ نقطه بدون سیل به طور 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 مطالعه حاضر، ۴۲۴ نقطه مکان سیل، شناسایی شد.

جدول ۱: عوامل موثر در سیلاب برای نگاشت حساسیت سیل

منابع	نقشه‌های مورد نیاز	داده‌ها
Search.asf.alaska.edu/#/	ارتفاع شاخص رطوبت، توپوگرافی TWI، شاخص توان جریان SPI، شیب، جهت شیب، انحنای تراکم شبکه زهکشی و فاصله از رودخانه دائمی، شاخص ماهواره‌ای توپوگرافی، شاخص رطوبت متفاوت نرمالیزه شده، همگرایی، جهت جریان، زمین شناسی	ALOSPALSAR (D.E.M./12.5 m)
Google Earth Engine	نقشه NDVI	Sentinel 2 (10 m) Google Earth Engin
Google Earth Engine	نقشه LU/LC	Land use/Land cover(10 m)
داده‌های هواشناسی	نقشه بارندگی	داده‌های بارندگی
(مرکز داده ISRIC، اطلاعات خاک جهان)	بافت خاک	داده‌های خاک
سازمان زمین شناسی ایران	زمین شناسی	اطلاعات زمین شناسی

¹ Mojaddadi

² Sarkar& Mondal

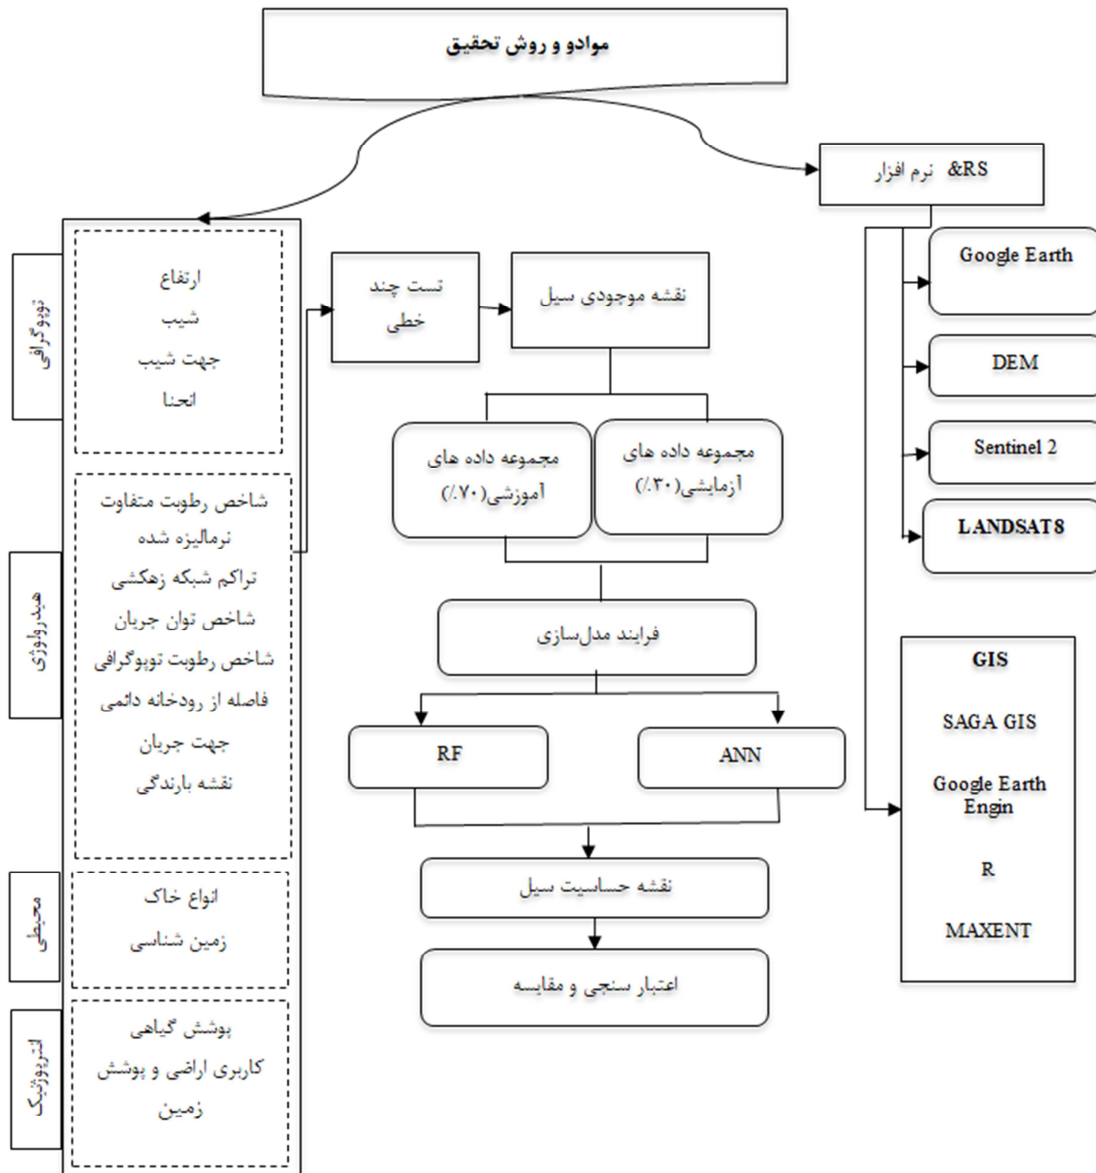
³ Liu

⁴ Benkirane

⁵ Google Earth Engine

⁶ Maxent

این نسخه موقت و قبل از چاپ نهایی می‌باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.



شکل ۲: مواد و روش تحقیق منبع: نگارندگان

یافته‌های تحقیق


ارزیابی چند خطی

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 چند خطی ۱۶ عامل مناسب سیل را نشان می‌دهد. TOL همه متغیرهای مورد استفاده در این مطالعه بالاتر از ۰/۲۶۲ است که نشان دهنده عدم وجود چند خطی بین این متغیرها است. بنابراین، ما از همه آنها در مرحله مدل سازی استفاده کردیم.

این نسخه موقت و قبل از چاپ نهایی می باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

جدول ۲: تجزیه و تحلیل چند خطی عوامل سیل ۱

متغیر	VIF	آمار
		خطی T_j
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 ۴: نمودار تجزیه و تحلیل چند خطی متغیر

تعیین اهمیت پارامترها

الگوریتم های مختلفی برای تعیین اهمیت متغیرهای موثر بر یک پدیده وجود دارد. در این تحقیق از نرم افزار R برای تعیین اهمیت پارامترها استفاده شده است.

معرفی پارامترهای منتخب و نقشه های آنها

شاخص های سیل بر اساس ویژگی ها، مقیاس منطقه مورد مطالعه و در دسترس بودن داده ها انتخاب شدند (بویی^۱ و همکاران، ۲۰۱۶). بر اساس ویژگی های سیلاب های تاریخی در منطقه مورد مطالعه و مشاهدات میدانی متعدد، ۱۶ عامل تأثیرگذار - ارتفاع، شیب، جهت شیب، فاصله از رودخانه ها، میانگین بارندگی ماهانه، کاربری زمین، بافت خاک، شاخص قدرت رودخانه، پوشش گیاهی، زمین شناسی، جهت جریان، شاخص رطوبت توپوگرافی، جهت جریان و انحنا را برای نقشه برداری حساسیت سیل انتخاب شد. شرح مفصلی از داده ها و منابع آنها ارائه شده است و نقشه های همه عوامل انتخاب شده 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). به طور معمول، ارتباط واضحی بین ارتفاع و سیل وجود دارد، زیرا مناطق با ارتفاعات پایین تر 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

این نسخه موقت و قبل از چاپ نهایی می‌باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

شیب: یکی از عوامل توپوگرافی است که در مطالعات هیدرولوژیکی موثر است. رابطه شیب با بارندگی این است که نفوذ بارندگی مستقیماً 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). نشان دهنده تمایل زمین به ریختن آب به مناطق مجاور پایین‌تر است (گروبر و پکهام^۳، ۲۰۰۹). مناطق مستعد سیل غالباً 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**: انحنا 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 نشان دهنده خطر بسیار مهم سیل است. شکل (۳ت).

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 (تگاواراپو^{۱۱}، ۲۰۱۲، ۱۰). و براحتال وقوع سیل تأثیر می‌گذارد (ورما^{۱۲} و همکاران، ۲۰۲۲). داده‌های بارندگی معمولاً در مطالعات تهیه نقشه سیل گنجانده می‌شوند، زیرا مستقیماً با پتانسیل سیل در ارتباط هستند (برا^{۱۳} و همکاران، ۲۰۲۲). شکل (۳چ).

کاربری اراضی: کاربری اراضی عاملی است که بر میزان نفوذ و رواناب حاصل از بارندگی موثر است (کازاکیس^{۱۴} و همکاران، ۲۰۱۵). شکل (۴ح).

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

¹⁴ Kazakis

این نسخه موقت و قبل از چاپ نهایی می‌باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

بافت خاک: نفوذ آب، که نقش مهمی در تولید رواناب بارندگی ایفا می‌کند، مستقیماً توسط خواص خاک تنظیم می‌شود (فیلیپس^۱ و همکاران، ۲۰۱۹) شکل (۴خ).

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

شاخص پوشش گیاهی متفاوت نرمالیزه شده (NDVI^۲): 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^۳ و همکاران، ۲۰۱۶، فاین^۴ و همکاران، ۲۰۱۷e). پوشش گیاهی، نقش بسزایی در بررسی حساسیت به سیل دارد (موهان^۵ و همکاران، ۲۰۱۸). شکل (۴ذ).

شاخص رطوبت توپوگرافی (TWI^۶): شاخص رطوبت توپوگرافی (TWI) معیاری است که برای تعیین کمیت تأثیر توپوگرافی بر فرآیندهای هیدرولوژیکی استفاده می‌شود (پور علی^۷ و همکاران، ۲۰۱۶) و تحت تأثیر تغییرپذیری مکانی رطوبت خاک است (وینزeler^۸ و همکاران، ۲۰۲۲) با استفاده از عامل شیب و انباشت جریان می‌تواند مناطق با پتانسیل سیل‌خیزی بالا شناسایی نماید (بویو همکاران، ۲۰۲۰). شکل (۴ر).

شاخص رطوبت متفاوت نرمالیزه شده (NDMI^۹): شاخص رطوبت تفاوت نرمال شده توسعه یافته توسط ویلسون و سادر (۲۰۰۲)، با هدف جستجو رطوبت خاک است. به طور معمول در مناطق پرآب و غرقاب رطوبت خاک زیاد خواهد بود (ساهو و بنگال^{۱۰}، 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 زیر توده‌های آبی عظیم و مقادیر پایین نشان‌دهنده رطوبت کم خاک است. شکل (۴ز).

شاخص ناهمواری توپوگرافی (TRI^{۱۱}): یک عامل کمک کننده مهم در تهیه نقشه حساسیت و نشان دهنده تغییر ارتفاع در یک منطقه مشخص از زمین است. هرچه مقدار TRI بالاتر باشد، زمین ناهموارتر است (آیدین و ایبان^{۱۲}، ۲۰۲۳). شکل (۴ز).

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

¹ Phillips

² Normalized difference vegetation index

³ Amadio

⁴ Fayne

⁵ Mohajane

⁶ Topographic Wetness Index

⁷ Pourali

⁸ Winzeler

⁹ Normalized difference moisture index

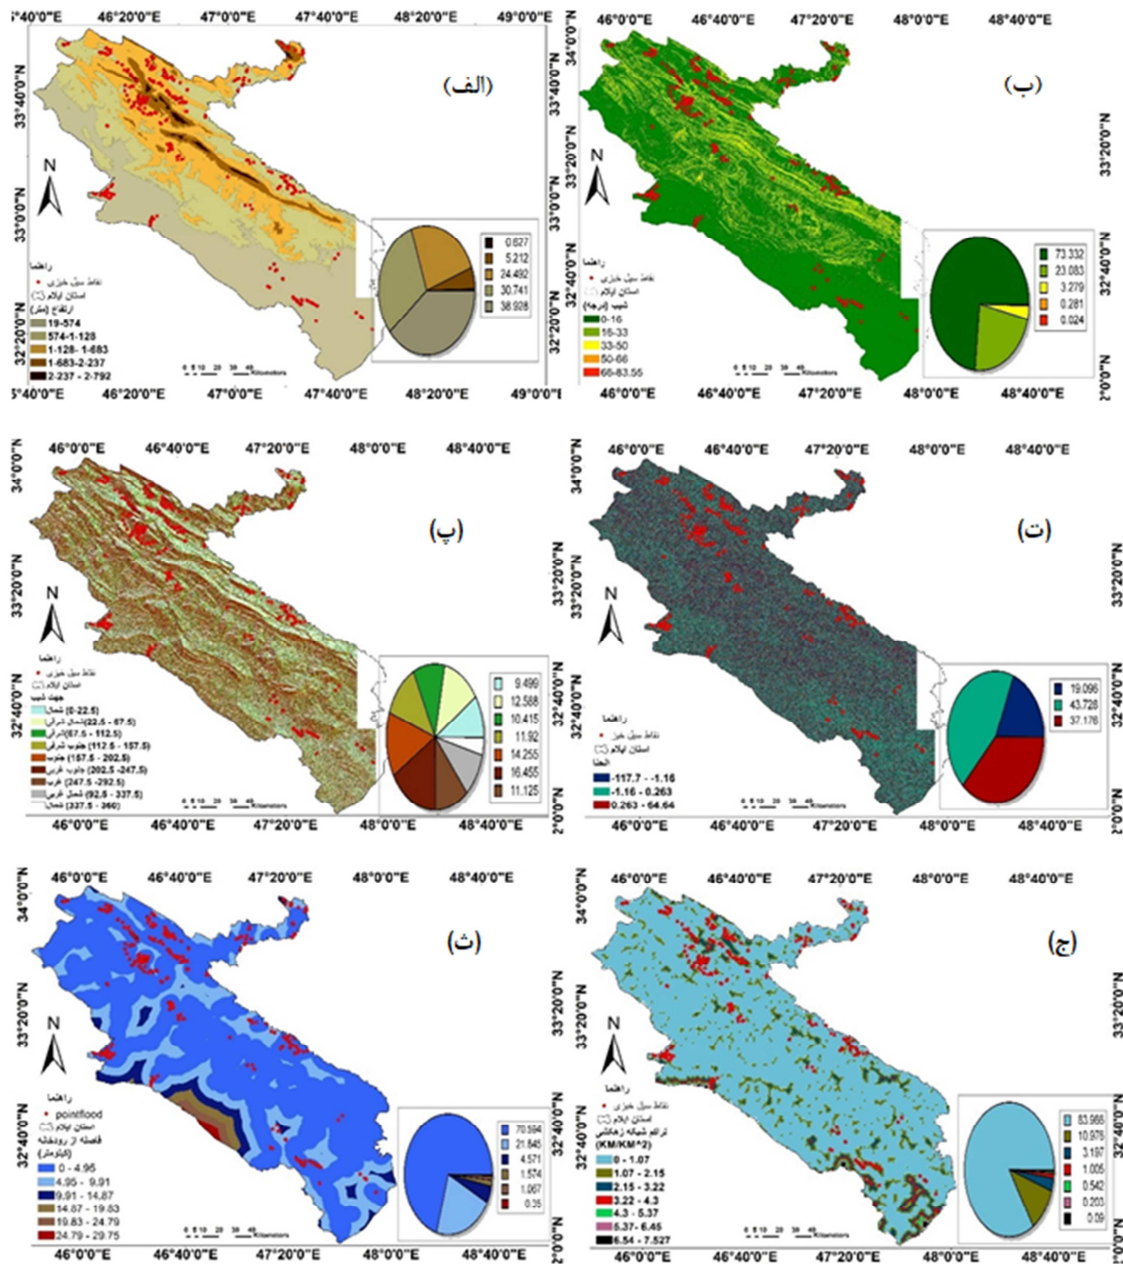
¹⁰ Sahu & Bengal

¹¹ Topographic roughness index

¹² Aydin & Iban

این نسخه موقت و قبل از چاپ نهایی می باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

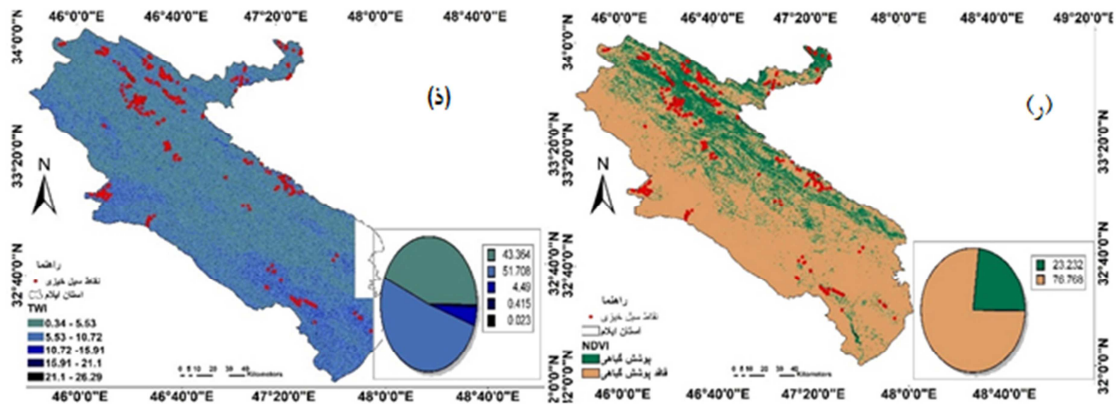
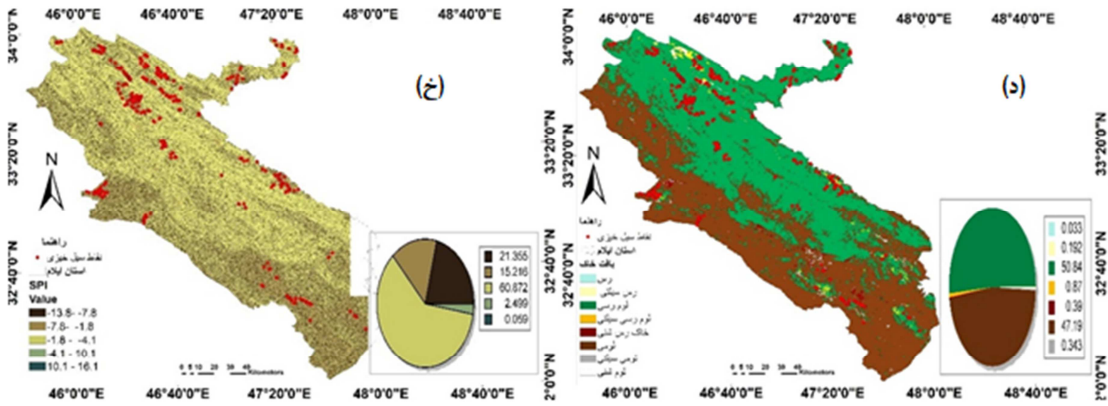
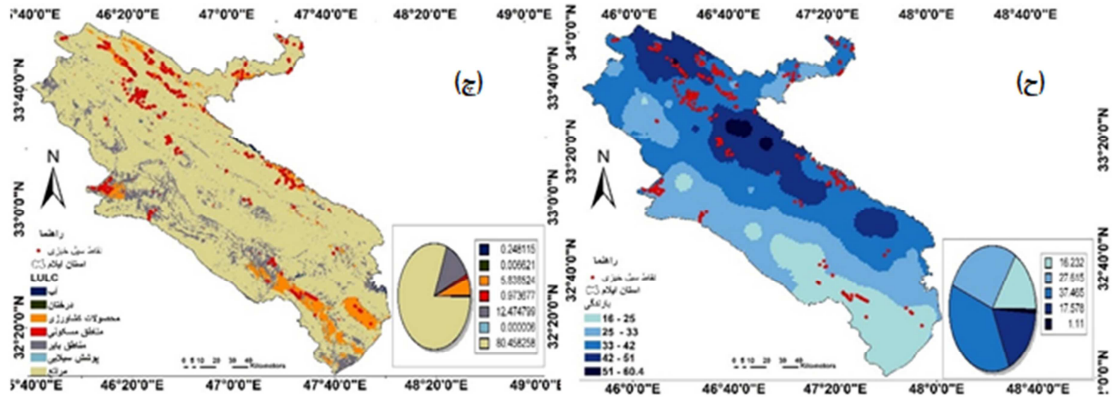
جهت جریان: یکی دیگر از عوامل مهم هیدرولوژیکی برای ارزیابی سیل است زیرا مسیر جریان را تحت تأثیر قرار می دهد و انباشت آب را تعیین می کند (خورونیس^۱ و همکاران، ۲۰۲۱، الجویدی^۲ و همکاران، ۲۰۱۸). در این مطالعه، جهت جریان از DEM (12.5 متر) تهیه شد. شکل (۴)ش.



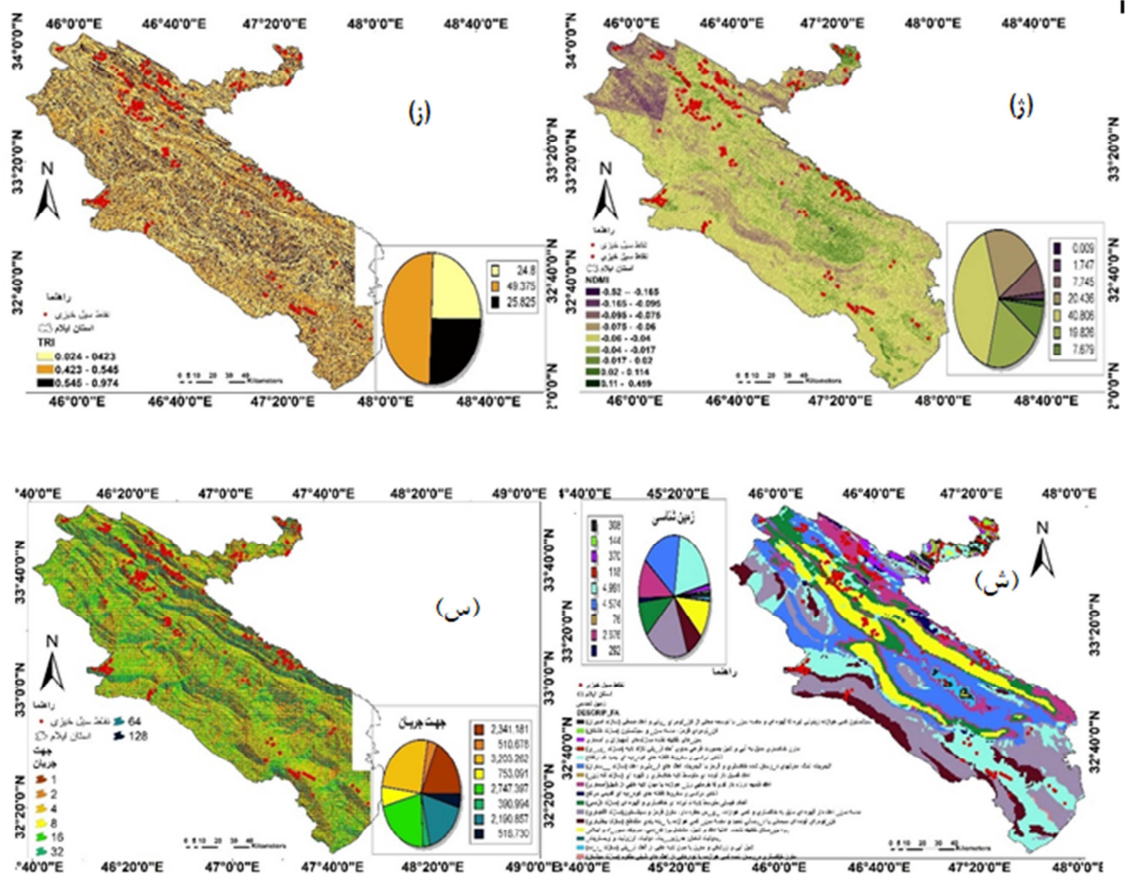
۱

¹ Khoirunisa
² Al-Juaidi

این نسخه موقت و قبل از چاپ نهایی می باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.



این نسخه موقت و قبل از چاپ نهایی می باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.



شکل ۴: نقشه عوامل مورد استفاده جهت حساسیت سیل: (الف) ارتفاع، (ب) شیب، (پ) جهت شیب، (ت) آنجن، (ث) فاصله از رودخانه، (ج) تراکم شبکه زهکشی، (چ) بارندگی، (ح) LULC، (خ) بافت خاک، (د) SPI، (ذ) NDVI، (ر) TWI، (ز) NDMI، (ز) TRI، (س) زمین شناسی، (ش) جهت جریان. منبع: نگارندگان

انتخاب مدل

در این مطالعه از الگوریتم‌های یادگیری ماشین برای ارزیابی حساسیت سیل استفاده شد. دو مدل، RF و ANN در محیط برنامه نویسی R پیاده سازی شد. از بسته‌های موجود و کتابخانه‌های متداول R برای بکارگیری 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 چند خطی بودن حساس نیست و نتایج آن در صورت وجود داده‌های گم شده یا نامتعادل نسبتاً ثابت است (چن^۲ و همکاران، ۲۰۲۰، یانگ و لی^۳، ۲۰۲۲e). که به طور گسترده برای مدل‌سازی حساسیت به سیل استفاده شده است (اسلام و همکاران، ۲۰۲۱).

¹ Yang & Li
² Chen
³ Yang & Li

این نسخه موقت و قبل از چاپ نهایی می‌باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

مدل شبکه عصبی مصنوعی (ANN¹)

شبکه‌های عصبی مصنوعی یکی از پرکاربردترین و دقیق‌ترین تکنیک‌های یادگیری ماشین است که توانایی بالایی در مدل‌سازی روابط غیرخطی بین متغیر هدف و متغیرهای توضیحی دارند (کیا² و همکاران، ۲۰۱۲) که چند بعدی هستند (کمپولو³ و همکاران، ۲۰۰۳). امروزه، شبکه‌های عصبی مصنوعی اغلب برای مدل‌سازی بلایای سیل استفاده می‌شود (ژانگ و چن⁴، ۲۰۱۹).

معیارهای ارزیابی مدل

ارزیابی دقت مدل یک گام مهم در هر تکنیک نقشه‌برداری پیش‌بینی است، زیرا اهمیت علمی مدل را مشخص می‌کند. این ارزیابی شامل مقایسه پیش‌بینی مدل‌ها بر روی داده‌های دیده نشده (داده‌های آزمایش) با نتایج شناخته شده از مجموعه داده آموزشی جداگانه است (چن⁵ و همکاران، ۲۰۲۲). ضریب تعیین (رایت⁶، ۱۹۲۱) را می‌توان به عنوان نسبت واریانس در متغیر وابسته که از متغیرهای مستقل قابل پیش‌بینی 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 با RMSE با استفاده از معادلات زیر برای تعیین دقت پیش‌بینی محاسبه شدند (معادل ۲، ۳، و ۴):

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

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

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

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

تهیه نقشه‌های آسیب پذیری سیل

لایه‌های رستری حساسیت به سیل در RStudio تولید شده برای نقشه برداری 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 طبقه بندی شکست‌های طبیعی استفاده شد. این روش به‌طور موثر داده‌ها را بر اساس توزیع داده‌های طبیعی و همسو با الگوهای فضایی وقوع سیل، طبقه بندی کرد. برای تکمیل احتمالات عددی، به هر کلاس یک برجسب کیفی از خیلی کم تا خیلی زیاد در مقیاس طبقه بندی اختصاص داده شد. این مبحث، روشی مناسب برای برقراری ارتباط اطلاعات مکانی پیچیده، ارائه می‌دهد.

¹ Artificial Neural Networks (ANN)

² Kia

³ Campolo

⁴ Zhang & Chen

⁵ Chen

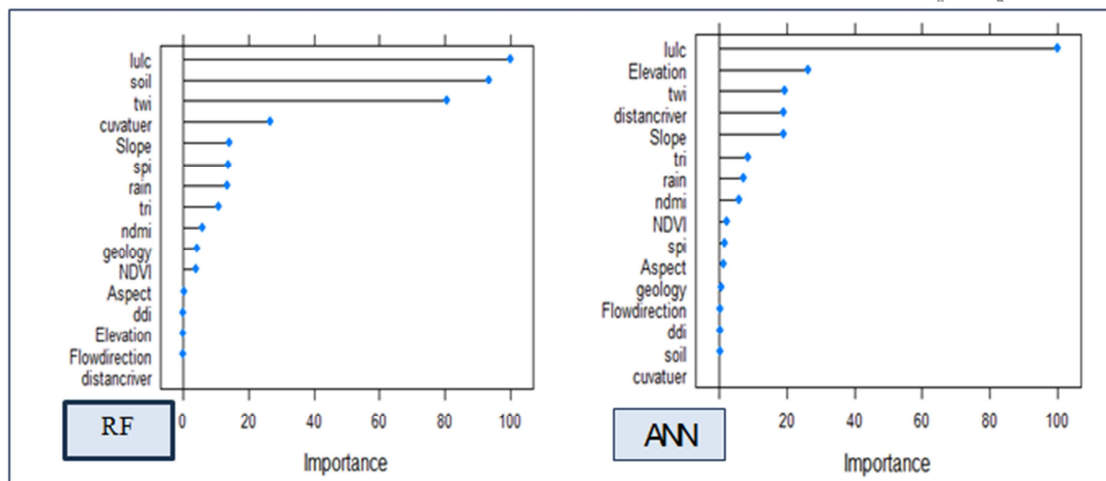
⁶ Wright

این نسخه موقت و قبل از چاپ نهایی می باشد. لطفا برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

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, 2020). ۱۶ لایه ورودی به عنوان 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 نرم افزار R ارزیابی شد نتایج نشان داد در هر دو مدل RF و ANN کاربری اراضی را به عنوان مهم‌ترین عامل شناسایی شد و در مدل RF عوامل انحنا، بافت خاک، تراکم شبکه زهکشی، جهت جریان، زمین شناسی، جهت شیب و در مدل ANN عوامل فاصله از رودخانه، جهت جریان، ارتفاع و تراکم شبکه زهکشی و جهت شیب به عنوان کم نفوذترین عوامل معرفی شدند. به طور کلی، مدل‌ها الگوی مشابهی را در اولویت‌بندی عوامل شرطی‌سازی برای حساسیت به سیل از خود نشان ندادند. این یافته‌ها از تحقیقات 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 شرطی سازی: (الف) RF، (ب) ANN

معیارهای ارزیابی و اعتبارسنجی مدل

این تحقیق با استفاده از معیارهایی مانند، MAE، Rsquared، RMSE، نتایج مدل را در برابر نقشه موجودی سیل به صورت کمی اعتبار سنجی کرد. نقشه‌های حساسیت سیل با استفاده از دو مدل RF و ANN تهیه شد. یافته‌های MAE، Rsquared و RMSE برای هر دو مدل مذکور 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 پیش بینی شده در مقایسه با مدل ANN بکار رفته در مطالعه داشت. این نشان می‌دهد که

این نسخه موقت و قبل از چاپ نهایی می باشد. لطفا برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

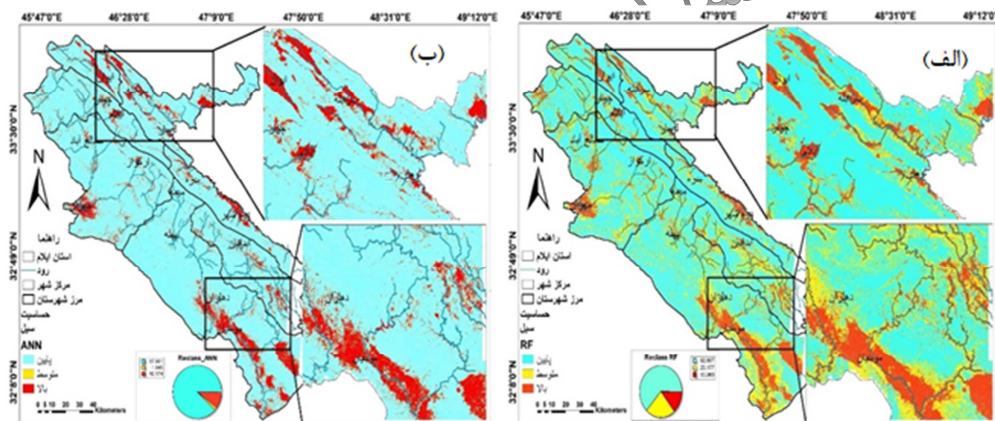
مدل های RF دارای درجه بسیار بالایی از مقبولیت همراه با نقص های کمتر در هنگام مدل سازی نقشه حساسیت سیل (FSM) است.

جدول ۳: ارزیابی دقت دو مدل RF و ANN برای داده های 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

نقشه های حساسیت به سیل برای هر دو مدل RF و ANN تولید شد. نقشه ها یک مقیاس احتمال پیوسته از (کمترین حساسیت) تا ۱ (بالاترین حساسیت) را نشان دادند. برای افزایش تفسیرپذیری نقشه ها با استفاده از روش شکست طبیعی به ۳ دسته طبقه بندی 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 می دهند. 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 می کند، در این تحقیق برای اولین بار با استفاده از مدل های یادگیری ماشین نقشه های موثر و قابل اعتماد خطر سیل برای منطقه تهیه شد.

این نسخه موقت و قبل از چاپ نهایی می‌باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

این نقشه‌ها بر مؤلفه خطر مدیریت ریسک بلایا تمرکز دارد و احتمال وقوع سیل در سراسر استان ایلام را نشان می‌دهند.

چندین مطالعه، فناوری‌های سنجش از دور را با یادگیری ماشینی ادغام کرده‌اند تا نقشه‌های حساسیت خطر سیل را توسعه دهند. به عنوان 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 تکنیک یادگیری ماشینی (RF، LightGBM، و CatBoost) برای تهیه نقشه‌های حساسیت به سیل (FSMs) استفاده کردند ۱۰ تا ۱۳ درصد از کل منطقه به شدت مستعد سیل است، رن و همکاران (۲۰۲۴) همچنین عملکرد مدل‌های یادگیری ماشینی را با استفاده از مجموعه داده‌های نامتعادل نقاط سیل و غیر سیل مشتق شده 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 واحی پست‌تر از عوامل مهم در قوع سیلاب هستند و مدل RF از نظر دقت پیش‌بینی بهتر از XGBoost عمل کرده.

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 شیل یا بررسی‌های میدانی به دست 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 آب و هوایی بسیار محتمل است. این تحقیق این شکاف‌ها را با استفاده از پهنه بندی مدل Maxent برطرف کرد. نقاط سیل با استفاده از مدل Maxent تهیه شد.

از موجودی سیل به دست آمده، 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 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 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^۴ و همکاران، ۲۰۲۳، حسن الزمان^۵، ۲۰۲۲).

مدل RF نشان داد که مساحت ۲۶۸۷،۹۹ کیلومتر مربع از استان ایلام "بسیار" مستعد خطر سیل است، در حالی که 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 به عنوان مناطق حساس به سیل "بالا" و "متوسط" شناسایی کرد.

¹ Hasanuzzaman

² Saber

³ Ahmad

⁴ Vu

⁵ Hasanuzzaman

این نسخه موقت و قبل از چاپ نهایی می‌باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

(جدول ۱۳). نتایج نشان داد که بر اساس مدل‌های ANN، RF، به ترتیب 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 «بالا» به طور جزئی کمتر از مدل RF است. نتایج نشان داد که شهر اکثراً 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 به دلیل 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 و دشت‌ها می‌شوند به دلیل تغییرات مورفولوژی و باز شدن دشت‌ها، آب از بستر طبیعی رودخانه‌ها خارج شده و وارد پهنه‌های دشتی سیل گیر 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 چند خطی بودن بین عوامل شرطی‌سازی شناسایی شده نشان نداد. یافته‌های اعتبارسنجی نشان داد که دو مدل استفاده شده عملکرد قابل توجهی داشتند. با این حال، RF از نظر محاسباتی، دقت پیش‌بینی و سایر معیارهای ارزیابی کارآمدتر از ANN است. که با مقدار $R^2 = 0/۸۴۲۳$ 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 به دلیل ظرفیت آن برای رسیدگی به انواع مختلف متغیرها ایجاد کند. این یافته‌ها با مطالعات قبلی مطابقت دارد (احمد و همکاران، ۲۰۲۵، وی^۱ و همکاران، ۲۰۲۳، حسن الزمان^۲، 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 آسیب پذیر 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

¹ Vu

² Hasanuzzaman

این نسخه موقت و قبل از چاپ نهایی می‌باشد. لطفاً برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

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 آب و هوایی 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، شماره 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، شماره ۱، ۸۹-۱۰۲.
- رشیدیان، مجتبی (۱۴۰۱). ارزیابی اثرات تغییر کاربری حال و آینده بر روی ریسک سیلاب، پایان‌نامه کارشناسی ارشد، دانشکده مهندسی عمران، دانشگاه خواجه نصیرالدین طوسی.
- سلامتی هرمزی، وحید، امیدوار، کمال، کاوسی‌رضا، حمزه نژاد، مجتبی، (۱۳۹۶). شناسایی و تحلیل هم‌دیدگی-دینامیکی الگوهای جوی سیلاب آبان ۱۳۹۴ در استان‌های ایلام و لرستان. نیوار، ۲۷، ۹۶-۹۷، ۴۱-۲۷.
- 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 سنجش از دور و سامانه اطلاعات جغرافیایی (GIS) منطقه مورد مطالعه: حوزه آبریز رودخانه مادرسو (پارک ملی گلستان)، پژوهش‌های محیط زیست، دوره ۱، شماره ۲، صص ۱۴-۱.
- لاهورتی 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، ۵۵(۱۰)، صص ۱۹۶۰-۱۹۳۹.
- 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.

این نسخه موقت و قبل از چاپ نهایی می باشد. لطفا برای ارجاع دقت کنید این نسخه بدون تاریخ و شماره است.

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.

آماده انتشار (بدون شماره مجله)