

Classification of critical flood areas based on artificial intelligence algorithms and combined with crowd wisdom methods (Case study: Rakaat Dezpart watershed)

Ghasem Shah Pari Far¹, Amin Zoratipour^{* 2}, Ashkan Yusefi³

1 M.Sc., Department of Engineering Geology, Faculty of Science, University of Isfahan, Isfahan, Iran

2* Department of Natural Engineering, Faculty of Agriculture, Khuzestan University of Agricultural Sciences and Natural Resources, Khuzestan, Iran

3 Department of Soil Science and Engineering, Faculty of Agriculture, Khuzestan University of Agricultural Sciences and Natural Resources, Khuzestan, Iran.

Extended Abstract

Introduction

Flooding is a major natural disaster, according to the UN, endangering lives, property, and societies more than any other. Mapping floodplains and modeling floods in mountain basins is essential for development projects, helping identify critical areas and control damage. A key 21st-century tool is satellite imagery, which provides valuable flood-related data. By processing these images, various information such as flooded areas, vegetation, lithology, slope, soil moisture, etc. can be calculated and estimated. In addition, machine learning algorithms have made it possible to estimate very complex relationships between various parameters and floods. However, these models require complex calibration and extensive data. Recently, many flood susceptibility models have been developed. Combining statistical and decision-making models with remote sensing and GIS has gained attention for improving predictive ability. Today, machine learning algorithms such as artificial neural networks, generalized linear algorithms, support vectors, and random forest models are used. Machine learning models are used in two aspects; one is to process and identify flooded areas, and the other is to zone and examine the importance of flood-intensifying parameters.

Materials and Methods

In recent decades, new methods have been used to identify the risk of flooding in basins and prepare maps of sensitivity to its occurrence, such as the use of multivariate statistical models, data mining, random forest methods, and machine learning methods. This study aimed to evaluate the performance of five machine learning models including random forest model, support vector model, generalized ensemble model, generalized linear model, classification and regression tree, and augmented tree regression (RF, SVM, BRT, CART, and GLM) in modeling flood probability in the northern mountainous basin of Khuzestan province. Also, to increase the stability and accuracy of the models, four ensemble methods were used, including simple mean, weighted mean, committee mean, and median. In the first step, thirteen different parameters were used as factors affecting the flood phenomenon, and using the collinearity test between the parameters, it was ensured that there was no strong relationship between each of them and other parameters. The factors studied are distance from the river, distance from the dam lake, curvature of the longitudinal profile of the waterway, curvature of the waterway plan, shape factor, river density, basin area, geology, vegetation, erosion factor, SPI index, TWI index, and curve number value. In this regard, the digital elevation model (DEM) of the region with an accuracy of 30 meters was extracted from the USGS website.

Results and Discussion

The AUC values for RF, BRT, SVM, CART and GLM models were estimated to be 0.932, 0.929, 0.885, 0.878 and 0.855, respectively. The results indicate that the random forest (RF) model has higher accuracy than other models in predicting flood risk in the study area. The results showed that all the models used

showed acceptable performance; however, tree-based models had a significant advantage over linear and SVM models. In particular, the random forest (RF) model achieved the best overall performance in predicting flood occurrence in the region, with the highest AUC value of 0.932. The boosted tree regression (BRT) model was followed by the least accurate model with an AUC of 0.929. In contrast, the generalized linear model (GLM) had the lowest accuracy among the individual models with an AUC of 0.855. In addition, the results from ensemble methods also showed that the values of AUC, TPR, and FPR parameters of these four methods are in the ranges of 0.919 to 0.926, 0.826 to 0.857, and 0.072 to 0.079. Among the methods studied, the average and weighted average methods have higher accuracy than the other two methods.

Conclusion

These findings emphasize the need to pay special attention to the spatial and hydrological characteristics of the basin in flood risk management planning and introduce the RF model and microaggregate approaches as effective strategies for preparing more accurate zoning maps. The use of four ensemble methods (Mean, WMean, Median, and Committee Averaging) resulted in more stable risk maps. Overall, the performance of these methods effectively reduced the uncertainty resulting from the selection of a single model. The simple mean (Mean) and weighted mean (WMean) methods provided more favorable results than the other ensemble methods due to their high accuracy (AUC = 0.926) and rapid convergence of results. This indicates that combining the outputs, with or without appropriate weighting (WMean), resulted in a more robust and repeatable estimate.

Keywords: Flooding, zoning, satellite images, Statistical techniques, Rakaat Khuzestan.

Article Type: Research Article

Acknowledgement

We would like to express our sincere gratitude to the University of Agricultural Sciences and Natural Resources of Khuzestan for the financial and logistical supports who significantly contributed during the research project.

Conflicts of interest

The authors of this article declared no conflict of interest regarding the authorship or publication of this article.

Data Availability Statement:

The datasets are available at a reasonable request to the corresponding author.

Authors' contribution

Ghasem Shahpari far: Software and statistical analysis of the research; **Amin Zoratipour:** Sampling, model implementation, model validation, writing the original version of the article; **Ashkan Usefi:** Conceptualization, consulting, text review, statistical and software analyses, and results control.

*Corresponding Author, E-mail: Zoratipour@asnrukh.ac.ir

Citation: Shah Pari Far, GH., Zoratipour, A., & Yusefi, A. (2026). Classification of critical flood areas based on artificial intelligence algorithms and combined with crowd wisdom methods (Case study: Rakaat Dezpart watershed). *Water and Soil Management and Modeling*, 6(3), 200-216.

doi: 10.22098/mmws.2026.19213.1772

Received: 07 January 2026, Received in revised form: 03 May 2026, Accepted: 20 May 2026, Published online: 27 August 2026.

Water and Soil Management and Modeling, Year 2026, Vol. 6, No. 3, pp. 200-216.

Publisher: University of Mohaghegh Ardabili© Author(s)





کلاسه بندی مناطق بحرانی سیل مبتنی بر الگوریتم های هوش مصنوعی و تلفیق با روش های خرد جمعی (مطالعه موردی: حوضه رکعت دزپارت)

قاسم شه پری فر^۱ , امین ذرتی پور^۲ , اشکان یوسفی^۳ 

۱ دانش آموخته کارشناسی ارشد، گروه زمین شناسی مهندسی، دانشکده علوم، دانشگاه اصفهان، اصفهان، ایران.
۲ دانشیار، گروه مهندسی طبیعت، دانشکده کشاورزی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان، خوزستان، ایران.
۳ گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان، خوزستان، ایران.

چکیده:

امروزه پهنه بندی پدیده سیلاب در حوضه های کوهستانی و مناطق صعب العبور، پیش نیاز توسعه در هر کشوری محسوب می شود و بایستی قبل از اجرای پروژه های مختلف صنعتی، عمرانی، شهرسازی و غیره؛ به وضعیت سیلاب حوضه و تعیین نقاط بحرانی توجه خاصی شود. این پژوهش با هدف ارزیابی عملکرد پنج مدل یادگیری ماشین شامل، مدل جنگل تصادفی، مدل بردار پشتیبان، مدل جمعی تعمیم یافته، مدل خطی تعمیم یافته، درخت طبقه بندی و رگرسیون، رگرسیون تقویت شده درختی (GLM، CART، BRT، SVM، RF) مدل سازی احتمال سیل در حوضه کوهستانی رکعت دزپارت در استان خوزستان انجام گرفت. همچنین، برای افزایش پایداری و دقت مدل ها، از چهار تکنیک خرد جمعی (Ensemble Methods)، شامل میانگین ساده، میانگین وزنی، میانگین کمیته ای و میانه استفاده شد. نتایج نشان داد تمامی مدل های مورد استفاده عملکردی قابل قبول از خود نشان دادند؛ با این حال، مدل های مبتنی بر درخت، برتری محسوسی نسبت به مدل های خطی و SVM داشتند. به طور خاص، مدل جنگل تصادفی (RF) با کسب بالاترین مقدار AUC برابر با ۰/۹۳۲، بهترین عملکرد کلی را در پیش بینی وقوع سیل در منطقه به خود اختصاص داد. پس از آن، مدل رگرسیون تقویت شده درختی (BRT) با AUC برابر با ۰/۹۲۹ در رتبه دوم قرار گرفت. در مقابل، مدل خطی تعمیم یافته (GLM) با AUC برابر با ۰/۸۵۵، کمترین دقت را در میان مدل های منفرد از خود نشان داد. همچنین تکنیک های خرد جمعی عملکرد مدل ها را بهبود بخشیدند؛ به طوری که مقادیر AUC برای روش های تلفیقی در محدوده ۰/۹۱۹ تا ۰/۹۲۶ قرار گرفت و پایداری پیش بینی ها را تقویت نمود. این یافته ها بر لزوم توجه ویژه به ویژگی های مکانی و هیدرولوژیکی حوضه در برنامه ریزی های مدیریت ریسک سیلاب تأکید می کند و مدل RF و رویکردهای خرد جمعی را به عنوان استراتژی های مؤثر برای تهیه نقشه های پهنه بندی دقیق تر معرفی می نماید.

واژگان کلیدی: سیل، پهنه بندی، تصاویر ماهواره ای، تکنیک های آماری، رکعت خوزستان

نوع مقاله: پژوهشی

*مسئول مکاتبات، پست الکترونیکی: Zorati pour@asnruk h.ac.ir

استناد: شه پری فر، قاسم، ذرتی پور، امین و یوسفی، اشکان (۱۴۰۵). کلاسه بندی مناطق بحرانی سیل مبتنی بر الگوریتم های هوش مصنوعی و تلفیق با روش های خرد جمعی (مطالعه موردی: حوضه رکعت دزپارت). مدل سازی و مدیریت آب و خاک، ۳(۳)، ۲۰۰-۲۱۶.

doi: 10.22098/mmws.2026.19213.1772

تاریخ دریافت: ۱۴۰۴/۱۰/۱۷ تاریخ بازنگری: ۱۴۰۵/۰۲/۱۳ تاریخ پذیرش: ۱۴۰۵/۰۲/۳۰ تاریخ انتشار: ۱۴۰۵/۰۶/۰۵

مدل سازی و مدیریت آب و خاک، سال ۱۴۰۵، دوره ۶ شماره ۳، صفحه ۲۰۰ تا ۲۱۶.

ناشر: دانشگاه محقق اردبیلی © نویسندگان



۱- مقدمه

سیل مهم‌ترین عامل مورفوکلیماتیک در تغییر شکل اراضی در مناطق کوهستانی محسوب می‌شود؛ به‌طوری‌که طبق آمار سازمان هواشناسی کشاورزی، بیش از سایر پدیده‌های اقلیمی جان، مال و شرایط اجتماعی انسان‌ها را در معرض خطر قرار می‌دهد، البته در صورتی که این پدیده خطرناک در جهت مشخصی، بهینه‌سازی شود، حتی می‌تواند برای اکوسیستم‌های طبیعی کاملاً مفید باشد و موجب تغذیه سفره‌های آب زیرزمینی، حاصلخیزی خاک و افزایش مواد مغذی در محل عبور رودخانه‌ها شود (Zhang et al., 2017). امروزه با تشدید تغییرات اقلیمی در عرض‌های جغرافیایی میانی، این خطر نسبت به گذشته رو به افزایش است؛ به‌گونه‌ای که برآوردها نشان می‌دهد، خسارت سیلاب در جهان از سال ۱۹۸۰ تا ۱۹۹۰ حدود ۱۴ میلیارد دلار بوده و در دوره ۲۰۰۴ تا ۲۰۱۴ به ۱۰۰ میلیارد دلار رسید. انتظار می‌رسد که در سال‌های آتی نیز این روند ادامه داشته و با افزایش سطح آب دریاها و تغییر رژیم بارش‌ها در دنیا تشدید شود (Wang et al., 2016). پدیده سیلاب به‌عنوان یکی از مخرب‌ترین مخاطرات طبیعی در کشور ایران، سالانه خسارات مالی و اجتماعی هنگفتی را بر جوامع تحمیل می‌کند، ضرورت ارتقای روش‌های پیش‌بینی و پهنه‌بندی خطر در مناطق بحرانی را دوجندان ساخته است. تعداد دفعات وقوع سیلاب در ایران در دهه‌های ۱۳۸۰ و ۱۳۹۰ در مقایسه با ۱۳۷۰ کاهش چشمگیری داشته اما در سال‌های ۱۳۹۰ تا ۱۳۹۸ سیلاب‌های مخربی در مناطق مختلف کشور حادث شده که با خسارات زیادی همراه بوده است. از جمله این سیلاب‌ها می‌توان به سیلاب‌های اواخر سال ۱۳۹۷ و فروردین ۱۳۹۸ در استان‌های شمالی و جنوب غربی کشور مانند گلستان، مازندران، لرستان و خوزستان اشاره کرد. در دی ماه ۱۳۹۸ نیز سیلاب مخرب موجب خسارات زیادی به استان سیستان و بلوچستان وارد نموده است. از همین‌رو پهنه‌بندی و ارزیابی مخاطرات طبیعی بخصوص سیلاب در مناطق کوهستانی می‌تواند ما را در ساماندهی و کنترل علمی و عملیاتی سیلاب‌ها و مدیریت پایدار آب‌خیزداری در مناطق پرخطر کمک شایانی نماید (Pavandmahr et al., 2025).

پهنه‌بندی سیل‌خیزی حوضه، اطلاعات ارزنده‌ای از این پدیده در اختیار کارشناسان و مدیران تصمیم‌گیرنده قرار می‌دهد. دستیابی به این اطلاعات، راهکارهای مقابله با این مخاطره طبیعی را ممکن و خسارات شدید آن را تقلیل می‌دهد. هرچه اطلاعات ما در خصوص عوامل تشدیدکننده این مخاطره کامل‌تر باشد، می‌توان اقدامات بهتری را در مقابله با آن اتخاذ کرد (Wang et al., 2023). یکی از بروزترین امکانات قرن ۲۱، استفاده از تصاویر ماهواره‌ای و داده‌های سنجنش از دوری تهیه شده توسط سنجنده‌ها است، که پردازش این تصاویر اطلاعات چشمگیری را در اختیار

کارشناسان قرار می‌دهد. با استفاده از پردازش این تصاویر، اطلاعات متعددی از جمله خصوصیات اداپیک و فیزیوگرافی مناطق سیل‌زده، ویژگی‌های کاربری اراضی و پوشش گیاهی، لیتولوژی، رطوبت خاک و ... قابل محاسبه و برآورد هستند. علاوه بر این اطلاعات، الگوریتم‌های یادگیری ماشین امکان برآورد روابط بسیار پیچیده بین پارامترهای مختلف و سیلاب را فراهم کرده است. از همین رو می‌توان گفت که با بهره‌گیری از این امکانات و دانش جدید، میتوان در آینده بر شناخت کنترل مخاطرات محیطی تسلط بیشتری داشت و تا حد ممکن خسارات ناشی از این نوع مخاطرات را به حداقل ممکن کاهش داد (Duwal et al., 2023). در دهه‌های اخیر روش‌های جدیدی به‌منظور شناسایی خطر سیلاب حوضه‌ها و تهیه نقشه‌های حساسیت به وقوع آن به‌کارگرفته می‌شود، از قبیل استفاده از مدل‌های آماری چند متغیره، داده‌کاوی، روش جنگل تصادفی و روش یادگیری ماشین است. اما لازم به ذکر است که استفاده از این مدل‌ها نیازمند کالیبراسیون پیچیده و داده اولیه بالایی هستند، از این‌رو در سال‌های اخیر مدل‌های زیادی برای تهیه نقشه حساسیت به وقوع سیل برآورده شده‌اند. در این میان، ترکیب مدل‌های آماری و تصمیم‌گیری با تکنیک‌های سنجنش از دور و سیستم اطلاعات جغرافیایی به‌دلیل بالا بردن توانایی مدل در پیش‌بینی، بسیار مورد توجه پژوهش‌گران بوده است (Zorati pour et al., 2025). امروزه استفاده از الگوریتم‌های یادگیری ماشین از جمله شبکه عصبی مصنوعی، الگوریتم خطی تعمیم‌یافته، بردار پشتیبان و مدل جنگل تصادفی مورد استفاده قرار می‌گیرند. مدل‌های یادگیری ماشین از دو جنبه مورد استفاده قرار می‌گیرند؛ جنبه ابتدایی به پردازش و شناسایی مناطق سیل‌زده می‌پردازد و جنبه دیگر، پهنه‌بندی و بررسی اهمیت پارامترهای تشدید کننده سیلاب است (Halder & Bose, 2024). در پژوهشی (Liu et al., 2019)، نیز در زمینه تهیه نقشه سیلاب در حوضه رودخانه‌ی جین‌شای در شرق فلات تبت چین، با به کارگیری روش جدید امکان تهیه نقشه‌های سیلاب را به صورت روزانه ارائه دادند بعلاوه، پژوهش صورت گرفته توسط Hu et al., (2019) نشان داد که یادگیری عمیق می‌تواند در شناسایی مناطق سیل زده در منطقه شرق سین تاکسیس در شرق حوضه هیمالیای کشور نپال، با استفاده از تصاویر ماهواره‌ای از دقت کافی برخوردار بوده و می‌تواند در پهنه‌بندی سیلاب کمک زیادی بنماید. بررسی میزان تأثیر عوامل مختلف و پیش‌بینی خطر سیلاب و تهیه نقشه پهنه‌بندی نیز از مهم‌ترین موضوعات مورد بررسی توسط پژوهشگران است. از آن‌جایی‌که روش پردازش اطلاعات توسط الگوریتم‌های یادگیری ماشین یکسان نیست، بررسی و مقایسه این مدل‌ها نیز از موضوعاتی است که مورد بررسی قرار

می‌گیرد. در این رابطه Maharjan et al., (2024)، با استفاده از یادگیری ماشین به بررسی احتمال خطر سیلاب در رودخانه موهانای نپال پرداختند و نتایج کار آنان نشان داد که تاثیر عوامل مختلف بر تشدید سیلاب یکسان نیست و الگوریتم‌های یادگیری ماشین از دقت بسیار خوب در زمینه پهنه بندی خطر سیلاب برخوردار هستند. پژوهشگران دیگری به بررسی کارایی الگوریتم‌های یادگیری ماشین بر اساس سامانه سیستم جغرافیایی پرداختند و دقت کافی آن را در پیش‌بینی خطر سیلاب مورد تأیید قرار داده اند (Zhang et al., 2017; Wang et al., 2023; Zoratipour et al., 2025).

مطالعات صورت گرفته همچنین نشان می‌دهد که نوع سیلاب‌ها و توزیع زمانی آن‌ها نسبت به گذشته تغییر کرده است. در همین راستا، نتایج مطالعه‌ای با استفاده از شکل هیدروگراف و پردازش سری زمانی، در چندین حوضه رودخانه‌ای در کشور آلمان در اروپا، نشان داد که سیلاب‌های حجیم در سال‌های اخیر از فراوانی بیشتری نسبت به گذشته برخوردار بوده اند. نتایج کار ایشان نشان می‌دهد که در آینده راه‌های مقابله با سیلاب و مدیریت آن نیز باید تغییر کند. طبیعی است مدیریت سیلاب‌های بزرگ به مراتب هزینه و برنامه جامع‌تری نیاز دارد. تغییر نوع سیلاب در سال‌های اخیر تحت تاثیر تغییرات اقلیمی است (Fischer and Schumann, 2025). با توجه به اهمیت پدیده سیلاب و خسارات جبران ناپذیری که این رویداد در مناطق کوهستانی استان خوزستان در ادوار گذشته داشته (به خصوص در حوضه رکعت دزپارت خوزستان که از سرشاخه‌های کارون بزرگ) (Pavandmehr et al., 2025)؛ بنابراین، ضرورت کلاسه‌بندی و ارزیابی این پدیده دوچندان می‌شود. این پژوهش با هدف کلاسه‌بندی مناطق بحرانی سیل با استفاده از الگوریتم‌های هوش مصنوعی و همچنین تلفیق آنها با روش‌های خرد جمعی است؛ در نهایت تولید و استخراج نقشه‌های خطر سیلاب به‌صورت کلاسه‌بندی‌شده، در حوضه آبخیز رکعت شهرستان دزپارت در شمال استان خوزستان انجام گرفت.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

حوضه آبخیز رکعت دزپارت خوزستان با مختصات جغرافیایی $31^{\circ}50'6''$ تا $31^{\circ}39'34''$ طول شرقی و $50^{\circ}03'20''$ تا $50^{\circ}08'$ عرض شمالی در محدوده ۶۰ کیلومتر سمت شرق شهر ایذه و در محدوده جغرافیایی شهرستان دزپارت استان خوزستان واقع شده است. مساحت حوضه ۱۶۳۴۶ هکتار است و از نظر تقسیمات

حوضه‌های آبخیز کشوری، از زیر حوضه‌های سد کارون ۳ به شمار می‌رود و عمدتاً دارای پوشش جنگلی است. چهار کاربری مختلف شامل جنگل، اراضی مرتعی، اراضی مرتعی به همراه اراضی دیم و رخنمون سنگی در منطقه موجود است. بیش‌ترین ارتفاع منطقه ۳۰۰۰ متر و کم‌ترین ارتفاع منطقه ۷۱۰ متر از سطح دریا است. همچنین، شیب متوسط حوضه حدود ۳۶ درصد بوده و بارش متوسط حوضه حدود ۵۴۰ میلی‌متر است. حوضه آبخیز رکعت یکی از حوضه‌های آبخیز مرتفع کوهستانی در شهرستان دزپارت استان خوزستان است که به دلیل کوهستانی بودن، پستی و بلندی‌های فراوان و پوشش گیاهی کم و نیز ریزش‌های قابل ملاحظه جوی، ویژگی‌های طبیعی و تشکیلات زمین‌شناسی مختلف یکی از مناطق مستعد به پدیده سیل است. غالب سازندهای زمین‌شناسی حوضه سازند آسماری و آهکی است همراه با فرسایش انحلالی بوده و در پایین‌دست، سازندهای دوره کواترنری همراه با رخساره‌های فرسایش شیار و آبراه‌های دیده می‌شود (Zoratipour et al., 2025). موقعیت حوضه رکعت دزپارت و تغییرات ارتفاعی آن در استان خوزستان به همراه نقشه نقاط مناطق سیلابی حوضه مذکور در شکل (۱) آورده شده است.


۲-۲- روش پژوهش

گام اول- انتخاب عوامل مؤثر بر پدیده سیلاب و رقومی-ساز

در این مطالعه به منظور مدل‌سازی پدیده سیلاب در حوضه رکعت خوزستان مبتنی بر الگوریتم یادگیری ماشین و تصاویر ماهواره‌ای (باتوجه به تحقیقات صورت گرفته نظیر، Duwal et al., (2023)، Fischer & Schumann (2025) و (Maharjan et al., 2024)، در اولین گام تعداد سیزده پارامتر مختلف، به‌عنوان عوامل مؤثر بر پدیده سیلاب مورد استفاده قرار گرفتند و با استفاده از آزمون هم‌خطی بین پارامترها از عدم وجود رابطه قوی بین هر کدام با سایر پارامترها اطمینان حاصل شد. عوامل مورد بررسی عبارتند از فاصله از رودخانه، فاصله از دریاچه سد، انحنا، پروفیل طولی آبراهه، انحنا، پلان آبراهه، ضریب شکل، تراکم رودخانه، مساحت حوضه، زمین‌شناسی، پوشش گیاهی، فاکتور فرسایش، شاخص خشکسالی (SPI)، شاخص رطوبت توپوگرافی (TWI)، مقدار شماره منحنی. در این رابطه مدل رقومی ارتفاعی (DEM) با دقت ۳۰ متر منطقه از وبسایت USGS استخراج شد، (https://earthexplorer.usgs.gov). همچنین درصد شیب، جهت شیب، شاخص رطوبت توپوگرافی، فاصله از

در قالب لایه‌های رستری تهیه شد. نقشه‌های فرسایش (از مدل USLE) و زمین‌شناسی، تبخیر و تعرق نیز به ترتیب از سازمان زمین‌شناسی و هواشناسی کشور تهیه شدند (شکل‌های ۲ و ۳).

رودخانه با استفاده از مدل ارتفاعی رقومی استخراج شدند. فاصله از جاده‌ها و روستاها نیز با استفاده از داده‌های ماهواره‌ای لندست ۸ تهیه شدند. ابتدا نقشه کاربری اراضی با استفاده از داده‌های لندست ۸ استخراج و سپس فاصله اقلیدسی از عوارض مختلف



شکل ۱- موقعیت حوزه کوهستانی دزپارت در استان خوزستان و ایران (بالا) و نقشه نقاط مناطق سیلابی و تغییرات ارتفاعی حوزه رکعت دزپارت خوزستان (پایین)

Figure 1- Location of the Dezpart mountain basin in Khuzestan province and Iran (above) and map of points in the floodplain areas of Rakaat basin the Dezpart, Khuzestan (below)

گام سوم - پایش نقاط سیلابی و بررسی داغاب حوضه مورد مطالعه


در گام دوم، با استفاده از تصاویر ماهواره‌ای و عملیات پیمایش صحرائی، نقشه سیلاب‌های گذشته تهیه شد. جهت بررسی عوامل متعدد از جمله شیب، ارتفاع، زمین‌شناسی، نقشه شماره منحنی (CN)، فاصله از آبراهه و دیگر عوامل در قالب لایه‌های رستری تهیه شد. ابتدا ۷۰ درصد از داده‌ها جهت یادگیری ماشین و سپس مابقی داده‌ها جهت اعتبارسنجی و بررسی میزان دقت هر یک از مدل‌ها استفاده شد (Pavandmehr et al., 2025) و (Duwal et al., 2023). در نهایت با به‌کارگیری هر یک از این مدل‌ها نقشه خطر سیلاب تهیه شد. به منظور بررسی و مقایسه

گام دوم - آزمون هم خطی

برای اطمینان از عدم وجود همبستگی چندگانه (میان متغیرهای پیش‌بین مستقل، یک تحلیل هم‌خطی صورت پذیرفت. پارامترهای عامل تورم واریانس (VIF) و خطای مجاز (Tolerance) به‌عنوان شاخص‌های اصلی برای شناسایی این پدیده به کار گرفته شدند. بر اساس نتایج، وجود VIF بزرگتر از ۱۰ یا Tolerance کوچکتر از ۰/۱، نشان‌دهنده بروز مشکل هم‌خطی است (Dias et al., 202

نتایج مدل‌ها، نقشه‌های احتمال سیل‌خیزی نقاط با استفاده از همه الگوریتم‌ها به‌دست آمد و طبقه‌بندی شد سپس بررسی آماری شدند. در مرحله بعد از نتایج شش مدل مورد استفاده جهت تهیه نقشه

نهایی سیلاب با روش خرد جمعی استفاده شد و در پایان به بررسی دقت خرد جمعی و مقایسه آن با نتایج هر یک از مدل‌ها پرداخته شد.




شکل ۲- لایه‌های مورد استفاده جهت تحلیل مدل‌های هوش مصنوعی سیلاب حوضه رکعت در یارت. a: شماره منحنی، b: کلاس فرسایش، c: پوشش گیاهی، d: سازندها، e: فاکتور شکل و f: انحنای پروفیل طولی آبراهه

Land Figure 2 - Layers used to analyze basin flood AI models a. Curve Number, b. Erosion Class, c. Shape Factor, f. Profile length stream. Cover, d. Formation, e.

سیلاب، به‌عنوان لایه باینری با دو کلاس کلی به مدل معرفی شد. مناطق دچار سیلاب با کد یک و سایر نقاط با کد صفر معرفی می‌شوند. همه نقاط به صورت کاملاً تصادفی به دو دسته تقسیم شدند (۷۰ درصد برای یادگیری و ۳۰ درصد برای تست کردن مدل). داده‌های یادگیری در این مرحله، جهت آموزش مدل انتخابی و داده‌های تست جهت اعتبارسنجی مورد استفاده قرار می‌گیرند. نتایج این پیش‌بینی به پنج کلاس خطر خیلی پایین (کم‌تر از ۲۰ درصد)، پایین (۲۰ تا ۴۰ درصد)، خطر متوسط (۴۰ تا ۶۰ درصد) و خطر زیاد (۶۰ تا ۸۰ درصد) و خیلی زیاد (بیش از ۸۰ درصد) طبقه‌بندی و ارائه می‌شود. در گام پایانی تحلیل اهمیت پارامترهای موثر، جهت مقایسه نسبی تاثیر این عوامل بر سیلاب یا استفاده از شش مدل مختلف یادگیری ماشین، صورت گرفت (Zorati pour et al., 2025).

گام چهارم - آموزش و امتحان (تست) الگوریتم‌های یادگیری ماشین و کلاسه‌بندی

در مرحله سوم، به منظور آموزش مدل‌های یادگیری ماشین، تعداد ۲۴۰ نقطه به صورت تصادفی برای مناطق با و بدون سیلاب (با کلیه کاربری‌های اراضی) در کل منطقه مطالعاتی انتخاب شد که از این تعداد حدود ۱۲۰ نقطه که بیش از ۵۰ درصد تغییرات در شاخص سیل‌خیزی منطقه حضور داشتند، مشخص شد. با توجه به پهنه وسیع محدوده مورد مطالعه، جهت آموزش مدل‌های یادگیری ماشین سعی شده است تا شبکه نقاط آموزش از تعداد کافی برخوردار باشد. در صورت محدود بودن تعداد نقاط آموزش، امکان بررسی روابط بین پارامترهای مستقل با سیلاب وجود ندارد و آموزش مدل‌های به کار برده شده به نحو مناسب صورت نمی‌پذیرد. در این گام، آموزش الگوریتم‌های یادگیری ماشین انجام گرفت. طی پروسه یادگیری ماشین مناطق دچار سیلاب و مناطق فاقد



شکل ۳- لایه‌های مورد استفاده جهت تحلیل سیلاب در حوضه رکعت دزبارت. g: شاخص رطوبت توپوگرافی، h: شاخص خشکسالی، i: مساحت پارسل، j: تراکم زهکشی، k: فاصله از رودخانه، l: فاصله از دریاچه و m: شیب (درصد)

Figure 3 - Layers used to analyze basin flood AI models, g. Humidity topographic index, h. Drout index, i. parsell area, j. Drainage density, k. length of stream, l. length of lake, m. slope percent.

پیش‌بینی درست پارامتر را نشان می‌دهد. در حالی که هر قدر این عدد به صفر نزدیک شود مدل دقت کم‌تری دارد. همچنین در کنار استفاده از نمودار ROC، از پارامترهای FNR، TNR، FPR، TPR و Efficiency می‌توان جهت تعیین دقت، کارایی و توانایی یک مدل استفاده نمود. (جدول ۱). که در این روابط، TP تعداد نقاط درست مثبت، FN تعداد نقاط اشتباه منفی، FP نقاط اشتباه مثبت و TN نقاط درست منفی را نشان می‌دهد (رابطه ۳، ۴ و ۵).

گام پنجم - ارزیابی و اعتبارسنجی مدل‌ها و ارزیابی پارامترها

میزان دقت هر مدل و توانایی آن در برآورد دقیق پارامتر اصلی با اعتبارسنجی مدل مشخص می‌شود. در این زمینه روش‌های متعدد مورد استفاده قرار می‌گیرد. یکی از بهترین روش‌ها استفاده از نمودار مشخصه نسبی عملکرد (ROC)^۱ است که میزان دقت یک مدل را نشان می‌دهد. مقدار نزدیک به یک دقت بالا و توانایی مدل در

¹ Relative Operating Characteristic

گام ششم- ارزیابی اهمیت پارامترهای تأثیرگذار

در این پژوهش همچنین آنالیز فاکتورهای تأثیرگذار بر سیلخیزی به طور واضح مورد بررسی قرار گرفت. بدین منظور در ادامه مطالعه، تغییرات صحت مدل با حذف هر پارامتر بررسی شد. تغییر صحت هر مدل با حذف هر پارامتر به عنوان اهمیت آن برآورد شد و سپس میانگین وزنی هر مدل با لحاظ کردن صحت آن مدل، محاسبه و مورد مقایسه قرار گرفت.

۲-۳-۲ کاربرد مدل‌های مختلف یادگیری ماشین

۲-۳-۱-۲ مدل جنگل تصادفی

مدل جنگل تصادفی یکی از کاربردی ترین مدل‌های یادگیری خردجمعی است که توسط بریمان (Breiman, 2001) ارائه شد. این مدل با ایجاد چندین درخت طبقه‌بندی و برآورد خرد جمعی همه درخت‌ها مدل نهایی را ایجاد می‌کند. مهم‌ترین پارامترهای این مدل تعداد درخت و ریشه مربع تعداد پارامترها هستند. همچنین این مدل از شاخص جینی به عنوان شاخص تقسیم استفاده می‌کند (جدول ۱، رابطه ۶).

۲-۳-۲-۲ مدل بردار پشتیبان

مدل بردار پشتیبان یکی از کاربردی ترین مدل‌های یادگیری ماشین بر اساس کاهش ریسک خطا است که توسط وپنیک (Vapnik, ۱۹۹۵). این روش داده‌های ورودی را در یک سطح تقسیم کرده و مرز بین هر یک از طبقات را به وضوح مشخص می‌کند. از داده‌های یادگیری ماشین جهت ایجاد تمایز بین کلاسه‌های مختلف و ارتباط آن‌ها با پارامتر وابسته استفاده می‌شود (Halder & Bose, 2024) (رابطه‌های ۷ تا ۱۰). برای اجرای SVM، داده‌های آموزشی مورد نیاز است. این داده‌ها فرایند جداسازی طبقات را بهینه‌سازی می‌کنند با استفاده از یک تابع پایه شعاعی (RBF)، پراکنش طبقات با محدوده‌های غیرخطی را می‌توان در یک محدوده جدا شده خطی ترسیم نمود (Hu et al., 2019). آموزش SVM با هسته تابع پایه شعاعی مستلزم تنظیم دو پارامتر است. یکی از این پارامترها، پارامتر منظم سازی است که تعادل بین به حداکثر رسانی حساسیت حواشی و به حداقل رساندن خطای آموزشی را برقرار کرده و کنترل می‌کند. طبقه‌بندی SVM شامل چهار نوع خطی، چند جمله‌ای، RBF و سیگموئید است. نوع RBF در بیشتر موارد به خوبی عمل می‌کند. ساختار ریاضی این چهار مدل در معادلات جدول (۱) نشان داده شده است. در این معادلات، x_i بردار پشتیبانی i ، x_j نقاط آموزش داده شده برای t ، پارامتر هموارسازی، k تابع مرکزی، II شاخص اقلیدسی،

γ پهنای هسته در توابع هسته مدل‌ها به جز مدل خطی، d نسبت درجه چند جمله ای در توابع هسته، γ نسبت بایاس در توابع هسته ای مدل‌های چند جمله‌ای و سیگموئید بوده و d و γ پارامترهای کنترل شده توسط کاربر است زیرا تعریف صحیح آن‌ها بطور قابل توجهی باعث افزایش دقت SVM می‌شود. (Maharjan et al., 2024)

۲-۳-۳-۲ مدل جمعی تعمیم یافته

مدل جمعی تعمیم یافته یک مدل ناپارامتری بوده و بسط مدل‌های خطی تعمیم یافته است که برخلاف مدل رگرسیونی خطی، داده‌ها شکل منحنی پاسخ را مشخص می‌کنند. در این مدل فرض بر این است که متغیر پاسخ دارای توزیعی از خانواده نمایی با میانگین است که از طریق تابع پیوند به متغیرهای تخمین گر متصل می‌شود. در مدل جمعی تعمیم یافته رابطه ۸ فرض بر این است که متغیر پاسخ Y دارای توزیع از خانواده نمایی با میانگین است که از طریق تابع پیوند (g) به متغیرهای تخمین گر (X_j) متصل می‌شود (رابطه ۱۱)، (Wang et al., 2023). (جدول ۱).

۲-۳-۳-۴ مدل خطی تعمیم یافته

مدل خطی تعمیم یافته یک مدل خطی وابسته جهت ارتباط بین پارامتر وابسته و پارامترهای مستقل فاقد توزیع نرمال است. این مدل طیف وسیعی از داده‌ها با توزیع نمایی را پوشش می‌دهد. با استفاده از تابع پیوند، متغیر پیشگو و اندازه گیری شده باهم ترکیب می‌شوند. این مدل ارتقاء یافته مدل خطی است که از حالت طبیعی داده‌ها استفاده می‌کند در نتیجه داده‌های مورد استفاده می‌توانند غیرخطی باشند. در مدل GLM، متغیرهای پیشگو $X_j (j=1,2,...,p)$ ترکیب شده و یک خط پیش بینی (LP) را ایجاد می‌نماید که وابسته به مقادیر مورد انتظار $\mu=E(Y)$ متغیر پاسخ Y است که از طریق تابع پیوند محاسبه می‌شود (رابطه ۱۲). که α عرض از مبدا، X متغیرهای پیش بینی کننده خطی، β ضریب رگرسیونی هر یک از متغیرهای پیشگو است. (جدول ۱). (Maharjan et al., 2024)

۲-۳-۵-۲ مدل درخت طبقه‌بندی و رگرسیون

الگوریتم طبقه‌بندی و رگرسیون نوعی الگوریتم طبقه‌بندی است که برای ساخت درخت تصمیم بر اساس شاخص ناخالصی جینی عمل می‌کند. در واقع این یک درخت است که به انواع زیر درخت تصمیم‌گیری اشاره می‌کند. به عبارت دیگر، CART یک تک رگرسیون یا درخت طبقه‌بندی است که با استفاده از حداکثر قواعد تصمیم، مکرراً داده‌ها را به گروه‌هایی تقسیم می‌کند و جهت بررسی پارامتر توصیفی مورد استفاده قرار می‌گیرد. یکنواختی خروجی داده‌ها در هر مرحله با استفاده از R^2 اندازه‌گیری می‌شود.

(2014. Rahimikhoob).

در روش میانگین ساده (Mean) مقدار خطر سیل خیزی برای

هر طبقه به‌صورت میانگین مستقیم نتایج مدل‌های پایه محاسبه شد. این روش فرض می‌کند که هر مدل سهم یکسانی در برآورد نهایی دارد و معمولاً برای ایجاد تصویری عمومی از رفتار مدل‌ها مفید است. در روش میانگین وزنی (Weighted Mean)، هر مدل بر اساس میزان دقت، شاخص عملکرد یا معیار اعتبارسنجی (مانند AUC یا Accuracy) دارای وزن مشخصی در ترکیب نهایی می‌شود. این روش نسبت به میانگین ساده نتایج واقع‌بینانه‌تری ارائه می‌دهد؛ زیرا مدل‌های قوی‌تر اثر بیشتری بر خروجی نهایی دارند. روش میانگین کمیته‌ای (Committee Averaging) مبتنی بر ایده تصمیم‌گیری گروهی است. در این رویکرد، پیش‌بینی هر مدل مانند رأی یک عضو کمیته در نظر گرفته می‌شود و خروجی نهایی به‌صورت میانگین آرای تمامی مدل‌ها به‌دست می‌آید. این روش معمولاً برای افزایش پایداری طبقه‌بندی و کاهش خطاهای ناشی از مدل‌های منفرد مورد استفاده قرار می‌گیرد. در روش میانه (Median)، مقدار نهایی برای هر طبقه خطر بر اساس میانه توزیع مقادیر مدل‌ها انتخاب شد. این روش در برابر داده‌های پرت یا خروجی‌های شدید مدل‌های خاص مقاوم است و نتایجی پایدار و محافظه‌کارانه‌تر ارائه می‌دهد (Shabani & Pourghasemi, 2020).

۶-۳-۲- مدل رگرسیون تقویت شده درختی

مدل رگرسیون تقویت شده یک الگوریتم یادگیری ماشین بر اساس درخت‌های طبقه‌بندی و رگرسیون همراه با الگوریتم تقویت است. در این روش با تلفیق مدل‌های ساده دقت مدل افزایش می‌یابد (Sharifani & Amini, 2023). رگرسیون تقویت شده درختی از دو الگوریتم استفاده می‌کند؛ الف) کلاس‌بندی و درخت رگرسیون و ب) ساخت و ترکیب چندین مدل به روش تقویت کردن. این روش مدل‌های دقیق‌تری نسبت به مدل‌های ساده ایجاد می‌کند بدین طریق این مدل بر مهم‌ترین نقص مدل‌های ساده غلبه کرده است. ابتدا اولین درخت با استفاده از همه داده‌ها ایجاد شده و سپس درختان بعدی با استفاده از داده‌های باقیمانده و درخت اول شکل می‌گیرند (Liu et al., 2019).


۷-۳-۲- مدل‌های خرد جمعی (Ensemble Methods)

به منظور افزایش دقت در پیش‌بینی احتمال سیل خیزی و کاهش عدم قطعیت ناشی از استفاده از مدل‌های منفرد، از روش‌های خرد جمعی مبتنی بر ترکیب خروجی مدل‌ها استفاده شد. در این پژوهش چهار روش خرد جمعی شامل میانگین ساده (Mean)، میانگین وزنی (Weighted Mean)، میانگین کمیته‌ای (Committee Averaging) و میانه (Median) برای تلفیق نتایج مدل‌های اصلی به‌کار گرفته شدند.

جدول ۱. روابط و معادلات متغیرهای مختلف مدل‌های هوش مصنوعی استفاده شده مطالعه

Table 1. Relationships and equations of various variables of artificial intelligence models used in the study

معادلات تعیین دقت و کارایی مدل‌ها		نوع معادلات
Tolerance = $1 - R^2_j$	رابطه ۱	معادلات تعیین دقت و کارایی مدل‌ها: در این روابط، TP، تعداد جواب‌های درست مثبت، FN، تعداد جواب‌های اشتباه منفی، FP، تعداد جواب‌های اشتباه مثبت و TN، جواب‌های درست منفی. T بیانگر دیتاست و r تعداد داده‌هایی است که در هیچ یک از کلاس‌ها قرار نمی‌گیرند.
VIF = $1/\text{Tolerance}$	رابطه ۲	
TPR = $TP/(TP+FN)$	رابطه ۳	
FPR = $FP/(FP+TN)$	رابطه ۴	
E = $(TP+TN)/(TP+TN+FP+FN)$	رابطه ۵	
معادلات مدل‌های مختلف الگوریتم یادگیری		نوع معادلات
$I_T(P) = \sum_{i=1}^j p_i \sum_{k \neq 1}^j p_k = 1 - \sum_{i=1}^j p_i^2$	رابطه ۶	معادلات مدل‌های مختلف الگوریتم یادگیری: در این معادلات، x_i بردار پشتیبانی x_j ، نقاط آموزش داده‌شده برای t پارامتر هموارسازی، k تابع مرکزی، II شاخص اقلیدسی، γ پهنای هسته در توابع هسته مدل‌ها به جز مدل خطی، d نسبت درجه چند جمله‌ای در توابع هسته، r نسبت بایاس در توابع هسته‌ای مدل‌های چند جمله‌ای و سیگموئید بوده d و r پارامترهای کنترل شده توسط کاربر است. (Duwal et al., 2023)
$K(x_i, x_j) = x_i^t, x_j$	رابطه ۷	
$K(x_i, x_j) = (\gamma \ x_i - x_j\ ^2 + r)^{-\gamma/2}, \gamma > 0$	رابطه ۸	
$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2), \gamma > 0$	رابطه ۹	
$K(x_i, x_j) = \tanh(-\gamma x_i x_j + r)$	رابطه ۱۰	
$g = (\mu) = \alpha + \sum_{j=1}^p = \int_j(x_i)$	رابطه ۱۱	
$g(E(Y)) = LP = \alpha + \beta Xr$	رابطه ۱۲	
		در اینجا فرض می‌شود که X_i توابعی نامعلوم و هموار و X_j متغیرهای تخمین‌گر هستند. به طور خاص X_i با استفاده از داده‌ها و با پراکنش استفاده از تکنیک‌های پیشرفته هموارساز نمودار پراکنش برآورد می‌شود. تفاوت اصلی مدل‌های جمعی تعمیم‌یافته با مدل‌های پارامتری در این است که توابع به وسیله توابع هموار نامعلوم جانشین می‌شوند. (Duwal et al., 2023)



شکل ۴- روش اجرای پژوهش

Figure 4 - Research implementation method


هم خطی (R^2) کم تر از ۰/۸ دارند. بنابراین، همبستگی و پدیده هم خطی بین این پارامترها در سطح ۸۰ درصد معنی دار نبوده و لذا برای استفاده در مدل سازی می توان از همه پارامترهای ذکر شده استفاده نمود. در ادامه مطالعه به منظور بررسی و مقایسه نتایج مدل ها، نقشه های احتمال سیل خیزی نقاط با استفاده از همه الگوریتم ها به دست آمد و طبقه بندی شد سپس بررسی آماری شدند. در نهایت نتایج این پیش بینی به صورت پنج کلاس خطر خیلی پایین (کم تر از ۲۰ درصد)، پایین (۲۰ تا ۴۰ درصد)، خطر متوسط (۴۰ تا ۶۰ درصد) و خطر زیاد (۶۰ تا ۸۰ درصد) و خیلی زیاد (بیش از ۸۰ درصد) طبقه بندی و ارائه شده است.

۳- نتایج و بحث

در این بخش، ابتدا نتایج حاصل از ارزیابی پیش نیازهای مدل سازی، شامل آزمون هم خطی پارامترهای ورودی ارائه می شود. پس از آن، عملکرد پنج الگوریتم یادگیری ماشین منفرد (RF، SVM، BRT، GLM، CART) در تخمین احتمال سیل خیزی در حوضه مورد مطالعه، به صورت توزیع پهنه بندی شده و آماری، مورد بررسی قرار می گیرد. در ادامه، تأثیر به کارگیری روش های خرد جمعی (Ensemble) بر بهبود پایداری پیش بینی ها و در نهایت، تحلیل اهمیت نسبی پارامترهای ورودی ارائه خواهد شد.


۳-۱- نتایج آنالیز هم خطی Multi-collinearity test

نتایج ارائه شده در (شکل ۵)، عدم وجود مشکل هم خطی بین پارامترها را نشان می دهد. نتایج نشان داد، همه پارامترها ضریب



شکل ۵- نمودار هیت مپ آزمون هم خطی بین پارامترهای مؤثر بر سیلاب حوضه رکعت در زپارت.

Figure 5- Heatmap diagram of the collinearity test between the parameters affecting the flood in the Rakaat basin of Dezpart.



شکل ۶- نتایج پیش‌بینی احتمال خطر سیلاب با استفاده از مدل‌های مختلف در حوضه رکعت دزیارت-ا. بردار پشتیبان b. جنگل تصادفی c. خطی تعمیم‌یافته d. درخت طبقه‌بندی و رگرسیون e. رگرسیون تقویت شده درختی

Figure 6 - Results of flood risk prediction using different models - a. Support Vector b. Random Forest c. Generalized Linear d. Classification and Regression Tree e. Boosted Regression Tree

زیاد و تقریباً ۱ درصد در رده خطر بسیار زیاد طبقه‌بندی شده است. این الگو بیانگر توزیع نسبتاً متعادل خطر در سطح منطقه است.

۳-۴- نتایج آنالیز احتمال سیل‌خیزی با استفاده از مدل جمعی تعمیم‌یافته

مدل جمعی تعمیم‌یافته نیز در این مطالعه به‌طور موفق مورد اجرا قرار گرفت و خروجی‌های آن در قالب پنج طبقه خطر سیلاب عرضه شده است. نتایج این مدل حاکی از آن است که ۸۸ درصد از پهنه در رده بدون خطر، ۱۰ درصد در طبقه خطر پایین، ۱/۵ درصد در سطح خطر متوسط، حدود ۰/۵ درصد در طبقه خطر زیاد و تنها ۰/۲ درصد در سطح خطر بسیار زیاد قرار دارد. الگوی توزیع خطر در این مدل، از غلبه نواحی کم خطر بر کل منطقه حکایت دارد.

۳-۵- نتایج آنالیز احتمال سیل‌خیزی با استفاده از رگرسیون تقویت شده درختی

برای پیش‌بینی احتمال وقوع سیلاب در شمال خوزستان از مدل رگرسیون تقویت‌شده درختی استفاده شد. نتایج حاصل به‌صورت نقشه‌های طبقه‌بندی شده در پنج سطح خطر ارائه شدند. بر مبنای نتایج، ۹۰ درصد از پهنه فاقد خطر یا در رده خطر خیلی پایین، ۵ درصد در طبقه خطر پایین، ۲/۵ درصد در خطر متوسط، ۱/۵ درصد

۳-۲- نتایج آنالیز احتمال سیل‌خیزی با استفاده از مدل جنگل تصادفی


به منظور ارزیابی میزان سیل‌خیزی در بخش شمالی استان خوزستان، مدل جنگل تصادفی به‌کار گرفته شد. نتایج این مدل نشان داد که بخش عمده‌ای از محدوده مطالعاتی، یعنی حدود ۸۹ درصد از کل پهنه، در رده خطر خیلی پایین قرار دارد. همچنین ۷ درصد از منطقه در طبقه خطر پایین، ۲/۵ درصد در سطح متوسط، و حدود ۰/۸ درصد در رده خطر زیاد و کمتر از ۰/۵ درصد در طبقه خطر خیلی زیاد واقع شده‌اند. نقشه‌های حاصل از طبقه‌بندی مدل، احتمال وقوع سیلاب را در قالب پهنه‌های مختلف خطر نشان می‌دهند (شکل ۶). بر اساس نقشه‌های خروجی (شکل ۶)، مناطق شمالی دارای بیشترین احتمال وقوع سیلاب هستند.

۳-۳- نتایج آنالیز احتمال سیل‌خیزی با استفاده از مدل بردار پشتیبان

مدل بردار پشتیبان نیز به‌عنوان یکی از الگوریتم‌های یادگیری ماشین در این پژوهش جهت پیش‌بینی سیل‌خیزی مورد استفاده قرار گرفت. خروجی مدل در قالب نقشه احتمال وقوع سیلاب ارائه شده است. بر اساس نتایج، حدود ۹۴ درصد از پهنه فاقد خطر، ۳ درصد در معرض خطر کم، و ۱ درصد در محدوده خطر متوسط قرار دارند، در حالی که کمتر از ۱ درصد از مساحت منطقه دارای خطر

۳-۷- نتایج آنالیز احتمال سیل‌خیزی با استفاده از روش‌های خرد جمعی

نتایج روش خرد جمعی در شکل (۷) و جدول (۲) ارائه شده است. نتایج نشان داد که تمامی روش‌های خرد جمعی در کاهش اختلاف بین مدل‌ها مؤثر بوده‌اند. بر اساس داده‌های جدول (۲)، روش‌های Mean و Weighted Mean مقادیر مشابهی را برای اکثر طبقات خطر نشان می‌دهند (به‌ویژه در طبقه خیلی پایین خطر با میانگین حدود ۹۱/۶ درصد)، که بیانگر همگرایی عملکرد مدل‌های اصلی در پیش‌بینی مناطق کم‌خطر است. درحالی‌که روش Committee Averaging با اندکی تفاوت (حدود ۹۲/۱۲ درصد در طبقه خیلی پایین) کمیتمایل به بزرگ‌نمایی خطر دارد. روش Median نیز نتایج متعادل‌تری ارائه کرده و از نوسان‌های شدید بین مدل‌ها جلوگیری کرده است (شکل ۷). در مجموع، استفاده از روش‌های خرد جمعی موجب افزایش دقت و کاهش عدم قطعیت در برآورد احتمال سیل‌خیزی شده است و انتخاب مناسب میان این تکنیک‌ها می‌تواند نقشه‌های پایدارتری از خطر سیلاب در مناطق مورد مطالعه فراهم نماید (جدول ۲). نتایج تحقیق با مطالعات Maharrjan, Pavandmehr et al., (2025) و همکاران (2023) مطابقت دارد.



شکل ۷- نتایج پیش‌بینی احتمال خطر با استفاده از روش‌های خرد جمعی- a. میانگین وزنی، b. میانگین، c. کمینه میانگین گیری، d. فاصله از رودخانه، e. میانه

Figure 6 - Results of hazard prediction using crowdsource methods - a. Weighted average, b. Mitengin, c. Minimum averaging, d. Distance from river, e. Median

در خطر زیاد و کمتر از ۱ درصد در طبقه خطر خیلی زیاد قرار دارند. الگوی خروجی مدل BRT با ارائه توزیع تفکیک‌شده خطر، توان قابل توجهی در پیش‌بینی سیل‌خیزی منطقه نشان داده است.

۳-۶- نتایج آنالیز احتمال سیل‌خیزی با استفاده از مدل خطی تعمیم‌یافته

در این تحقیق، مدل خطی تعمیم‌یافته نیز برای بررسی احتمال وقوع سیلاب در محدوده شمالی استان خوزستان مورد استفاده قرار گرفته است. نتایج حاصل در قالب نقشه‌های احتمال سیل‌خیزی در پنج طبقه خطر (خیلی پایین، پایین، متوسط، زیاد و خیلی زیاد) ارائه شده‌اند. بر اساس خروجی مدل، حدود ۸۰ درصد از پهنه در سطح خطر خیلی کم تا کم، ۱۷ درصد در طبقه خطر متوسط، و تنها ۳ درصد از منطقه در رده خطر زیاد و خیلی زیاد قرار دارند. این داده‌ها نشانگر کارایی قابل قبول مدل GLM در تشخیص مناطق مستعد وقوع سیلاب می‌باشند.

جدول ۲- توزیع خطر سیل‌خیزی در مدل‌های مختلف و روش‌های خرد جمعی

Table 2- Distribution of flood risk in different models and crowd-sourced methods

Susceptibility Class	RF	GLM	SVM	BRT	CART	Mean	WMean	Committee Averaging	Median
Very Low Susceptibility	89.37	87.97	93.68	90.09	93.95	91.63	91.62	92.12	91.97
Low Susceptibility	7.25	9.73	3.23	5.41	2.47	5.03	5.03	5.58	4.82
Moderate Susceptibility	2.46	1.57	1.17	2.43	0.75	2.36	2.36	0.31	2.16
High Susceptibility	0.82	0.56	0.72	1.53	0.88	0.90	0.090	1.73	0.88
Very High Susceptibility	0.09	0.18	1.20	0.53	1.94	0.09	0.09	0.26	0.16

مطالعات Maharjan, Sharifani & Amini (2023) و همکاران

(2023) مطابقت دارد.

مقادیر حساسیت (TPR) برای مدل‌های RF، BRT، CART، SVM و GLM به ترتیب ۰/۷۸۰، ۰/۶۶۷، ۰/۷۶۰ و ۰/۴۵۵ و مقادیر ویژگی یا خطای نوع دوم (FPR) به ترتیب ۰/۰۷۵، ۰/۰۶۱، ۰/۰۷۵، ۰/۰۷۹ و ۰/۰۹۲ محاسبه شد. این نتایج بیانگر دقت مناسب کافی مدل‌های مورد استفاده در ارزیابی سیل‌خیزی منطقه هستند. بر اساس شاخص‌های AUC، TPR و FPR می‌توان نتیجه گرفت که تمام مدل‌ها عملکرد قابل قبولی دارند، اما به طور کلی بهره‌گیری از مدل‌های RF و BRT با دقت بیشتری نسبت به مدل‌های دیگر می‌تواند به مدیران منابع آب در اولویت‌بندی پروژه‌های آبخیزداری کمک کند. نتایج تحقیق با مطالعات Zoratipour و همکاران (2025)، Nur & Mondal (2023) مطابقت دارد.

علاوه بر این، نتایج حاصل از روش‌های خرد جمعی (Ensemble methods) نیز نشان داد که مقادیر پارامترهای AUC، TPR و FPR این چهار روش در محدوده‌های ۰/۹۱۹ تا ۰/۹۲۶، ۰/۸۲۶ تا ۰/۸۵۷، و ۰/۰۷۲ تا ۰/۰۷۹ قرار دارند. میان روش‌های مورد بررسی، روش‌های میانگین و میانگین وزنی دقت بالاتری نسبت به دو روش دیگر دارند.

جدول ۳- نتایج اعتبارسنجی مدل‌های یادگیری ماشین با استفاده از پارامترهای مختلف

Table 3 - Validation results of machine learning models using different parameters

Model	AUC	TPR	FPR	TNR	FNR	Efficiency	TSS
RF	0.932	0.759	0.075	0.925	0.241	0.918	0.684
BRT	0.929	0.780	0.061	0.939	0.220	0.930	0.719
SVM	0.885	0.760	0.079	0.921	0.240	0.915	0.681
CART	0.878	0.667	0.075	0.925	0.333	0.912	0.591
GLM	0.855	0.455	0.092	0.908	0.545	0.894	.363
Mean	0.926	0.857	0.072	0.928	0.143	0.925	0.785
WMean	0.926	0.857	0.072	0.928	0.143	0.925	0.785
Median	0.919	0.828	0.702	0.928	0.172	0.924	0.756
Committee Averaging	0.92	0.826	0.079	0.921	0.174	0.918	0.747


۸-۳- تخمین اعتبار Validation Assessment

ارزیابی و اعتبارسنجی روش‌های یادگیری ماشین، نقش مهمی در درک بهتر عملکرد

مدل‌ها، تحلیل دلایل و روند تغییرات، و پیش‌بینی پارامترهای زیست محیطی مانند شرایط آینده گیاهان دارد (Rahimikhob, 2014). با این حال، استفاده از تنها یک روش برای اعتبارسنجی مدل‌ها کافی نیست (Saha et al., 2020). در این پژوهش، از چندین رویکرد مختلف برای ارزیابی صحت مدل‌ها استفاده شده است.

پنج مدل یادگیری ماشین شامل RF، SVM، GLM، BRT و CART با بهره‌گیری از شاخص‌هایی مانند نمودار ROC، مقدار AUC، راندمان (Efficiency)، حساسیت (TPR) و ویژگی (FPR) مورد اعتبارسنجی قرار گرفتند. این شاخص‌ها توان پیش‌بینی مدل‌ها را نشان می‌دهند (شکل ۸).

مقادیر AUC برای مدل‌های RF، BRT، SVM، CART و GLM به ترتیب ۰/۹۳۲، ۰/۹۲۹، ۰/۸۸۵، ۰/۸۷۸ و ۰/۸۵۵ برآورد شد. نتایج گویای آن است که مدل جنگل تصادفی (RF) از دقت بالاتری نسبت به سایر مدل‌ها در پیش‌بینی خطر وقوع سیلاب در منطقه مورد مطالعه برخوردار است (جدول ۳). نتایج تحقیق با



شکل ۸- نمودار ROC مدل‌های مختلف یادگیری ماشین

Figure 8 - ROC chart of different machine learning models

۴- نتیجه گیری

شیب، کاربری اراضی و شاخص‌های اشباع خاک) و پدیده سیل برمی‌شود. در مقابل، مدل خطی تعمیم‌یافته (GLM) با AUC برابر ۰/۸۵۵ کمترین کارایی را داشت، که این امر بر ماهیت غالباً غیرخطی پدیده‌ی سیل‌خیزی در مناطق کوهستانی تأکید می‌کند و استفاده از مدل‌های خطی ساده را برای این پدیده‌های محیطی پیچیده نامناسب می‌سازد.

توزیع پهنه‌بندی خطر توسط مدل‌های منفرد نیز تفاوت‌های قابل توجهی را در تخمین سطح خطر نشان داد. به‌عنوان مثال، مدل SVM پهنه‌بندی با کمترین درصد مناطق «بدون خطر» (۹۴٪) و بیشترین درصد مناطق «خیلی زیاد» (حدود ۱٪) را ارائه داد، که نشان‌دهنده حساسیت بیش از حد این مدل به داده‌های پرت یا مرزهای کلاس است. در نقطه مقابل، مدل RF یک توزیع متعادل‌تر با ۸۹٪ پهنه «خیلی پایین» خطر ثبت کرد که نشان‌دهنده برآورد واقع‌بینانه‌تری از ریسک کلی منطقه است. این نوسانات در نتایج مدل‌های منفرد، به طور قاطع، لزوم استفاده از روش‌های تلفیقی (Ensemble) را برای کاهش عدم قطعیت و افزایش پایداری (Robustness) پیش‌بینی‌ها آشکار ساخت.

استفاده از چهار روش خرد جمعی (Mean، WMean، Median و Committee Averaging) منجر به ایجاد نقشه‌های خطر پایدارتر شد. به طور کلی، عملکرد این روش‌ها با AUC در محدوده ۰/۹۱۹ تا ۰/۹۲۶، به طور مؤثری عدم قطعیت ناشی از انتخاب یک مدل منفرد را کاهش دادند. روش‌های میانگین ساده (Mean) و میانگین وزنی (WMean) به دلیل دقت بالا (AUC در

این پژوهش با هدف ارزیابی عملکرد پنج مدل یادگیری ماشین (جنگل تصادفی (RF)، بردار پشتیبان (SVM)، رگرسیون تقویت شده درختی (BRT)، مدل خطی تعمیم‌یافته (GLM) و درخت طبقه‌بندی و رگرسیون (CART) در مدل‌سازی احتمال سیل‌خیزی در حوضه کوهستانی شمال استان خوزستان انجام شد و سپس از تکنیک‌های خرد جمعی (Ensemble) برای بهبود پایداری و دقت پیش‌بینی‌ها بهره برد.

نتایج اعتبارسنجی مدل‌ها (بر اساس معیارهای AUC، TPR و FPR) نشان داد که تمامی رویکردهای انتخاب شده توانایی مناسبی برای تمایز بین کلاس‌های مختلف خطر سیل دارند، اما تفاوت‌های چشمگیری در کارایی آن‌ها مشاهده شد. در این میان، مدل جنگل تصادفی (RF) با بالاترین مقدار AUC برابر ۰/۹۳۲، بهترین عملکرد کلی را از خود به نمایش گذاشت. پس از آن، مدل رگرسیون تقویت شده درختی (BRT) با AUC معادل ۰/۹۲۹ در رتبه دوم قرار گرفت. این برتری مدل‌های مبتنی بر درخت، از جمله RF و BRT، کاملاً با یافته‌های مطالعات پیشین (Duwal et al., 2023) در حوزه‌های پیش‌بینی بلایای طبیعی مطابقت دارد. در نهایت مدل جنگل تصادفی (RF) از دقت بالاتری نسبت به سایر مدل‌ها در پیش‌بینی خطر وقوع سیلاب در منطقه مورد مطالعه برخوردار است. این عملکرد بهتر، به توانایی ذاتی این الگوریتم در مدل‌سازی روابط غیرخطی پیچیده بین عوامل محیطی (مانند

دسترسی به داده‌ها

همه اطلاعات و نتایج در متن مقاله ارائه شده است. داده‌ها و نتایج استفاده شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

مشارکت نویسندگان

قاسم شه‌پری‌فر: آنالیزهای آماری و ارزیابی، تهیه نقشه‌ها، مرور منابع، نگارش پیش‌نویس طرح؛ امین ذرتی پور: مفهوم‌سازی، راهنمایی، تجزیه و تحلیل و بررسی، ویرایش و بازبینی مقاله؛ اشکان یوسفی: اعتبارسنجی، نمونه برداری و بررسی، ویرایش و بازبینی مقاله.

منابع

ذرتی پور، امین، شه‌پری‌فر، قاسم، یوسفی، اشکان. (۱۴۰۴). مدل‌سازی تغییرات پوشش جنگل‌های استان خوزستان مبتنی بر الگوریتم یادگیری ماشین و تصاویر ماهواره. تحقیقات آب و خاک ایران. ۵۶(۸)، ۲۰۵۷-۲۰۷۷. doi:10.22059/ijswr.2025.394576.669934
رحیمی‌خوب، علی (۱۳۹۴). مقایسه بین مدل درختی M5 و شبکه‌های عصبی برای تخمین تبخیر و تعرق مرجع در یک محیط خشک. مدیریت منابع آب، ۲۸ (۲)، ۶۴۹-۶۵۷. <http://jstnar.iut.ac.ir/article-1-2499-fa>.
شریفانی، کریم، و امینی، مریم (۱۴۰۲). یادگیری ماشین و یادگیری عمیق: مروری بر روش‌ها و کاربردها. مجله جهانی فناوری اطلاعات و مهندسی، ۱۰(۰۷)، ۳۸۹۷-۳۹۰۴. doi:10.1016/j.world.tec.eng.2023.e10.3897-3904.

References

Aksoy, S., Sertel, E., Roscher, R., Tanik, A., & Hamzehpour, N. (2024). Assessment of soil salinity using explainable machine learning methods and Landsat 8 images. *International Journal of Applied Earth Observation and Geoinformation*, 130, 103879. doi:10.1016/j.jag.2024.103879.
Buba, F. N., Gajere, E. N., & Ngum, F. F. (2020). Assessing the Correlation between Forest Degradation and Climate Variability in the Oluwa Forest Reserve, Ondo State, Nigeria. *American Journal of Climate Change*, 9(4), 371-390. doi:10.4236/ajcc.2020.94023.
Dias, F., Suhadolnik, N., Camargo, H., & Da Silva, S. (2024). Predicting the pulse of the Amazon: Machine learning insights into deforestation dynamics. *Journal of Environmental*

حدود ۰/۹۲۶) و همگرایی سریع نتایج، نتایج مطلوب‌تری نسبت به سایر روش‌های تلفیقی ارائه دادند. این موضوع نشان می‌دهد که ترکیب خروجی‌ها، چه با وزن‌دهی مناسب (WMean) و چه بدون آن (Mean)، به یک برآورد قوی‌تر و با تکرارپذیری بالاتر منجر شده است. این امر با مطالعات مشابهی همچون Maharjan و همکاران (۲۰۲۳)، Duwal و همکاران (۲۰۲۳)، که کارایی روش‌های میانگین‌گیری در بهبود عملکرد مدل‌های طبقه‌بندی را تأیید می‌کنند، همخوانی دارد.

در نهایت نتیجه‌گیری شد، مدل جنگل تصادفی (RF) به‌عنوان بهترین مدل منفرد و روش‌های میانگین (Mean/WMean) به‌عنوان مؤثرترین استراتژی تلفیقی برای مدل‌سازی احتمال سیل‌خیزی در شمال استان خوزستان معرفی می‌گردند. این نتایج، مبنایی ارزشمند برای تدوین نقشه‌های پهنه‌بندی خطر سیل با دقت بهبودیافته و در نهایت، برنامه‌ریزی مؤثرتر منابع و کاهش خسارات در منطقه فراهم می‌آورد. با این حال، شایسته است تحقیقات آتی بر روی اعتبارسنجی پارامترهای SPI در دوره‌های زمانی بلندمدت و ادغام داده‌های سنجش از دور برای پایش لحظه‌ای وضعیت رطوبت خاک متمرکز شوند تا دقت پیش‌بینی‌ها بیش از پیش ارتقاء یابد.

سپاس‌گزاری

در این بخش از همکاری و مساعدت معاونت آموزشی و معاونت پژوهشی دانشگاه علوم کشاورزی و منابع طبیعی خوزستان در انجام مراحل مختلف پژوهش از جمله در اختیار قرار دادن وسیله نقلیه، بازدیدهای میدانی و غیره قدردانی می‌شود.

تضاد منافع نویسندگان

نویسندگان این مقاله اعلام می‌دارند که هیچ‌گونه تضاد منافی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

Management, 362,121359. doi:10.1016/j.jenvman.2024.121359.
Duwal, S., Liu, D., Pradhan, P.M., (2023). Flood susceptibility modeling of the Karnali river basin of Nepal using different machine learning approaches. *Geomatics, Nat. Hazards Risk* 14 (1), 2217321. doi:10.1080/19475705.2023.2217321.
Fischer, S., and Schumann, H. (2025). Dominant flood types in Europe and their role in flood statistics. *Hydrological Sciences Journal*. 994-1010. doi:10.1080/02626667.2025.2450369.
Halder, S., Bose, S., 2024. Comparative study on remote sensing-based indices for urban ecology assessment: A case study of 12 urban centers in the metropolitan area of eastern India. *Journal of Earth System Science*. 133: 100. doi:10.1007/s12040-024-02321-3.

- Hu, K.H., Zhang, X., You, Y., Hu, X.D., Liu, W.M., Li, Y., 2019. Landslides and dammed lakes 805 triggered by the 2017 Ms6.9 Milin earthquake in the Tsangpo gorge. *Landslides* 16(5), 993- 806 1001. doi:10.1007/s10346-019-01168-w.
- Kumar, B. P., Babu, K. R., Anusha, B. N., & Rajasekhar, M. (2022). Geo-environmental monitoring and assessment of land degradation and desertification in the semi-arid regions using Landsat 8 OLI/TIRS, LST, and NDVI approach. *Environmental Challenges*, 8, 100578. doi: 10.1016/j.envc.2022.100578.
- Liu, W.M., Carling, P.A., Hu, K.H., Wang, H., Zhou, Z., Zhou, L.Q., Liu, D.Z., Lai, Z.P., Zhang, 829 X.B., 2019. Outburst floods in China: A review. *Earth Sci. Rev.* 197, 102895. doi: 10.1016/j.earscirev.2019.102895.
- Maharjan, M., Timilsina, S., Ayer, S., Singh, B., Manandhar, B., & Sedhain, A. (2024). Flood susceptibility assessment using machine learning approach in the Mohana-Khutiya River of Nepal. *Natural Hazards Research*. 4:24-35. doi: 10.1016/j.nhres.2024.01.001.
- Nur, I., Mondal, P., (2023). GIS-based machine learning algorithm for flood susceptibility analysis in the Pagla river basin, Eastern India. *Natural Hazards Research*. 3:420-436. doi: 10.1016/j.nhres.2023.05.004.
- Pavandmehr, P., Zoratipour, A., Moazami, M., & Cheraghi, M. (2025). Flood vulnerability zoning is based on remote sensing indices and decision-making techniques (Case study: Rakat basin of Khuzestan). *Water and Soil Management and Modeling*, 5(2), 234-250. doi:10.22098/mmws.2024.15911.1501.[In Persian]
- Rahimikhoob, A. (2014). Comparison between M5 model tree and neural networks for estimating reference evapotranspiration in an arid environment. *Water Resources Management*, 28, 657-669. <http://jstnar.iut.ac.ir/article-1-2499-fa>. [In Persian].
- Saha, S., Saha, M., Mukherjee, K., Arabameri, A., Ngo, P. T., T., & Paul, G. C. (2020). Predicting the deforestation probability using the binary logistic regression, random forest, ensemble rotational forest, REPTree: A case study at the Gumani River Basin, India. *Science of the Total Environment*, 730, 139197. doi: 10.1016/j.scitotenv.2020.139197.
- Shabani, S., Pourghasemi, H. R., & Blaschke, T. (2020). Forest stand susceptibility mapping during harvesting using logistic regression and boosted regression tree machine learning models. *Global Ecology and Conservation*, 22, e00974. doi: 10.1016/j.gecco.2020.e00974.
- Sharifani, K., & Amini, M. (2023). Machine learning and deep learning: A review of methods and applications. *World Information Technology and Engineering Journal*, 10(07), 3897-3904. doi:10.1016/j.world.tec.eng.2023.e10.3897-3904.
- Wang, Z., Wang, Y., Liu, Y., Wang, F., Deng, W., & Rao, P. (2023). Spatiotemporal characteristics and natural forces of grassland NDVI changes in Qilian Mountains from a sub-basin perspective. *Ecological Indicators*, 157, 111186. doi: 10.1016/j.ecolind.2023.111186.
- Zhang, B., He, X., Ouyang, F., Gu, D., Dong, Y., Zhang, L., ... & Zhang, S. (2017). Radiomic machine-learning classifiers for prognostic biomarkers of advanced nasopharyngeal carcinoma. *Cancer Letters*, 403, 21-27. doi: 10.1016/j.canlet.2017.06.004.
- Zoratipour, A., Shahparifar, Q. and Yousefi, A. (2025). Modeling changes in forest cover in Khuzestan province based on machine learning algorithm and satellite images. *Iranian Soil and Water Research*. 56(8), 2057-2077. doi:10.22059/ijswr.2025.394576.669934. [In Persian]