

Flood risk zoning using a combination of machine learning models via Stacking Ensemble

Masoumeh Yeganeh^{*1}, Afshin Ashraf Zadeh²

¹M.Sc. Student, Department of Water Engineering, Faculty of Agriculture, Ferdowsi University of Mashhad, Mashhad, Iran

²Associate Professor, Department of Irrigation and Drainage Engineering, Faculty of Agriculture, University of Tehran, Karaj, Iran

Corresponding Author's E-mail: masomeh.yeganeh@alumni.um.ac.ir

Received: 23 Oct. 2025
Revised: 07 June 2026

Accepted: 15 June 2026
Published: 21 June 2024



Homepage: ijwer.uoz.ac.ir

Abstract: Flood hazard mapping is essential for disaster-risk management and urban planning. This study developed a Stacking ensemble framework using RF, SVM, and LightGBM models with logistic regression as a meta-model to improve flood vulnerability prediction. The dataset was normalized, and SMOTE was applied to overcome class imbalance. Among 683 flood events, 70% were used for training and 30% for validation. Ten environmental factors, including rainfall, elevation, drainage density, slope, land use, and geology, were analyzed. Sensitivity analysis identified rainfall, elevation, and drainage density as the most influential factors. The RF+SVM+LightGBM ensemble achieved the best performance, with accuracy of 0.88, kappa of 0.81, F1-score of 0.87, AUC of 0.92, and RMSE of 0.34. The results confirm that the proposed framework provides accurate flood hazard mapping and supports effective urban planning and disaster management.

Keywords: Random forest algorithm, Support vector machine, Flood zoning, LightGBM

Introduction: Floods are among the most destructive natural hazards, causing considerable human, economic, and environmental damages worldwide each year. The increasing frequency and intensity of flood events due to climate change, rapid urban expansion, and improper land-use changes have highlighted the necessity of developing accurate and efficient methods for identifying flood-prone areas. Flood hazard zoning is considered an essential component of disaster risk management, providing valuable information for mitigation strategies, sustainable land-use planning, and reducing the vulnerability of human settlements and infrastructures (Saber et al., 2023). Traditional flood assessment approaches often face limitations due to the complexity of interactions among environmental factors and the uncertainty associated with hydrological processes. Therefore, the application of advanced machine learning techniques has recently gained attention due to their ability to analyze complex relationships between flood occurrence and conditioning factors. This study aims to evaluate and compare the performance of two widely used machine learning algorithms, Random Forest (RF) and Support Vector Machine (SVM), for flood hazard zoning in the Navrud watershed, located in Guilan Province, Iran (Fig. 1). The findings of this research can contribute to improving flood prediction accuracy and supporting effective decision-making in watershed management and disaster mitigation planning.

Methodology: In this study, a set of factors affecting flood occurrence, including distance from the watercourse, drainage density, flow direction, slope, slope direction, precipitation, elevation, land use, and geology, were used as input variables (Figs. 2 and 3). Historical flood occurrence data were also used to train and validate the models. To prepare the data, different information layers were first prepared in a geographic information system (GIS) environment and then used in an integrated manner to analyze machine learning models. Random Forest (RF) Algorithm: This algorithm is an ensemble learning method that provides stronger predictions by building a large number of decision trees and combining their results. RF model ability to handle outliers, nonlinear features, and the lack of need for specific statistical assumptions make it suitable for flood zoning problems. Support Vector Machine (SVM) Algorithm: SVM is a powerful algorithm for classification problems that works by finding an optimal hyperplane that best separates the data. The use of different kernel functions (such as RBF) allows SVM to model complex nonlinear relationships between input variables and flood occurrence. To validate the models,

the data was divided into two parts: training (70%) and testing (30%). The performance of the models was evaluated and compared using metrics such as Accuracy, Sensitivity, Specificity, and Area Under the ROC Curve (AUC).

Results and Discussion: The results of this study demonstrated that both Random Forest (RF) and Support Vector Machine (SVM) algorithms have a strong capability for identifying and zoning flood-prone areas in the Navrud watershed. The performance evaluation of the models indicated that machine learning approaches can effectively capture the complex relationships between flood occurrence and environmental conditioning factors. The importance analysis revealed that drainage density, geology, land use, and elevation were the most influential parameters affecting flood susceptibility in the study area, respectively (Fig. 4). Drainage density showed the highest contribution, as areas with dense drainage networks are more likely to experience rapid runoff concentration and increased flood potential. In addition, geological characteristics and land-use patterns influenced infiltration capacity and surface runoff generation, while elevation affected water accumulation and flood propagation processes. A comparison of the predictive performance of the models showed that the SVM algorithm provided higher accuracy than the RF model. The SVM model achieved an AUC value of 0.97, whereas the RF model obtained an AUC value of 0.93, indicating the superior ability of SVM in distinguishing flood-prone and non-flood-prone areas. Furthermore, based on the evaluation metrics, including RMSE and R^2 , the SVM model showed better predictive performance, with RMSE and R^2 values of 0.26 and 0.89, respectively, compared with the RF model (Table 1). The generated flood susceptibility maps indicated that downstream areas and regions near the watershed outlet are more vulnerable to flooding. This higher susceptibility is mainly related to lower elevation, gentle slopes, and the convergence of river channels, which facilitate water accumulation and flood expansion. The flood zoning maps produced by both models showed strong consistency with historical flood occurrence records, confirming their reliability for flood hazard assessment (Figs. 7-9). Overall, the results highlight the effectiveness of machine learning models as valuable tools for flood risk management and watershed planning.

Conclusion: The findings of this study confirm the effectiveness of Random Forest (RF) and Support Vector Machine (SVM) algorithms as reliable and powerful approaches for flood hazard zoning. Both models demonstrated a high capability in identifying flood-prone areas and can be considered suitable alternatives to conventional flood assessment methods. Their application can provide valuable support for decision-makers in developing preventive strategies, improving land-use planning, and reducing the adverse impacts of flood events. However, the SVM model showed superior performance compared with RF, particularly in conditions involving high-dimensional datasets, limited samples with specific structures, and applications requiring accurate classification with optimal separation boundaries. Therefore, SVM can be a more efficient choice for complex flood susceptibility assessments.

© 2024 University of Zabol, Zabol, Iran.



This is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0 license) (<http://creativecommons.org/licenses/by/4.0/>)

پهنه‌بندی خطر سیلاب با استفاده از تلفیق مدل‌های یادگیری ماشین (یادگیری جمعی پشته‌ای)

معصومه یگانه^{۱*}، افشین اشرف زاده^۲

^۱ دانشجوی کارشناسی ارشد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه فردوسی مشهد، مشهد، ایران

^۲ دانشیار، گروه مهندسی آبیاری و زهکشی، دانشکده کشاورزی، دانشگاه تهران، کرج، ایران

پست الکترونیکی نگارنده مسئول: masomeh.veganeh@alumni.um.ac.ir

وبگاه نشریه: ijwer.uoz.ac.ir



تاریخ دریافت: ۱۴۰۴/۰۸/۰۱ تاریخ پذیرش: ۱۴۰۵/۰۳/۲۵

تاریخ ویرایش: ۱۴۰۵/۰۳/۱۷ تاریخ چاپ: ۱۴۰۳/۰۴/۰۱

چکیده: پهنه‌بندی خطر سیلاب ابزاری کلیدی در مدیریت ریسک بلایا و برنامه‌ریزی شهری است. در این پژوهش، یک چارچوب پشته‌ای (Stacking) برای ارتقای دقت پیش‌بینی نقشه‌های آسیب‌پذیری سیلاب توسعه داده شد. سه ترکیب مدل شامل RF+LightGBM، SVM+LightGBM و RF+SVM+LightGBM ساخته شد و رگرسیون لجستیک به‌عنوان فرامدل به‌کار رفت. داده‌ها پس از نرمال‌سازی و استفاده از روش SMOTE برای رفع عدم‌توازن کلاس‌ها به مدل‌ها وارد شدند و عملکرد با داده‌های آزمون مستقل ارزیابی شد. از میان ۶۸۳ رخداد سیلاب، ۷۰٪ (۴۶۶ رخداد) برای آموزش و ۳۰٪ (۲۰۰ رخداد) برای اعتبارسنجی به‌کار رفت. ده عامل موثر در پهنه‌بندی شامل فاصله از آبراهه، تراکم زهکشی، جهت جریان، شیب، جهت شیب، بارش، رقوم ارتفاعی، کاربری اراضی و زمین‌شناسی انتخاب گردید. تحلیل حساسیت نشان داد بارش، رقوم ارتفاعی و تراکم زهکشی بیشترین اثر را دارند. نتایج بیانگر برتری مدل سه‌گانه RF+SVM+LightGBM بود که به‌دقت ۰/۸۸، ضریب کاپا ۰/۸۱ امتیاز F1 وزنی ۰/۸۷ و مقدار AUC برابر ۰/۹۲ دست یافت. در مقابل، مدل‌های RF+LightGBM و SVM+LightGBM به‌ترتیب با دقت‌های ۰/۸۴ و ۰/۸۳، کاپا ۰/۷۶ و ۰/۷۴ و مقادیر AUC برابر ۰/۸۸ و ۰/۸۷ عملکرد ضعیف‌تری داشتند. همچنین RMSE مدل‌ها به‌ترتیب ۰/۳۴، ۰/۳۹ و ۰/۴۱ بود که بیانگر کاهش خطای مدل سه‌گانه است. منحنی‌های ROC نیز توان تفکیک بالاتر این مدل را در تشخیص نواحی مستعد و غیرمستعد سیلاب تایید کرد؛ بنابراین، چارچوب پیشنهادی می‌تواند ابزاری مطمئن برای تصمیم‌گیری، ارائه نقشه‌های دقیق خطر سیلاب و پشتیبانی از برنامه‌ریزی شهری و مدیریت بحران باشد.

کلیدواژه‌ها: الگوریتم جنگل تصادفی، مدل ماشین بردار پشتیبان، پهنه‌بندی سیل، یادگیری دسته‌ای، گرادیان بوستینگ سبک

طبیعی است که سالانه خسارات جانی و مالی فراوانی به جوامع انسانی وارد می‌سازد. در این شرایط، شناسایی و مدیریت مناطق پرخطر اهمیت ویژه پیدا کرده است.

۱- مقدمه

یکی سیلاب یکی از مهم‌ترین و مخرب‌ترین مخاطرات

نشان دادند که روش‌های ترکیبی نسبت به مدل‌های منفرد از دقت بیشتری برخوردارند. (Xu et al. (2023) ترکیب مدل LightGBM و مدل‌های هیدرولوژیک، رویکردی سریع برای پیش‌بینی سیلاب شهری ارائه دادند که برتری آن نسبت به مدل‌های RF و XGBoost تایید شد.

در پژوهشی دیگر (Ganjirad and Delavar (2023) به مقایسه RF و SVM در نقشه‌برداری مناطق مستعد سیلاب پرداختند و نشان دادند که انتخاب الگوریتم به ویژگی‌های محیطی منطقه وابسته است.

نتایج مطالعاتی (Zhang et al. (2025) بر اهمیت داده‌های با وضوح مکانی و زمانی بالا در بهبود دقت مدل‌ها تاکید داشته‌اند. افزون بر این، پژوهش‌های اخیر به کاربرد تکنیک‌های انتخاب ویژگی و روش‌های توضیح‌پذیری مدل‌ها (XAI) توجه داشته‌اند تا علاوه بر افزایش دقت، قابلیت تفسیر نتایج برای تصمیم‌گیرندگان نیز ارتقاء یابد.

مطالعات (Alam et al. (2025) و (Yang et al. (2024) نشان داده‌اند که ترکیب روش‌های یادگیری جمعی با رویکردهای بهینه‌سازی بیزی و الگوریتم‌های فراابتکاری، می‌تواند دقت نقشه‌های خطر سیلاب را افزایش دهد. همچنین، رویکردهای جدید مبتنی بر شبکه‌های عمیق^۳ در سال‌های اخیر مورد توجه قرار گرفته‌اند، اگرچه نیازمند داده‌های بزرگ و محاسبات سنگین هستند.

مرور پیشینه نشان می‌دهد که اگرچه مدل‌های درختی و یادگیری جمعی در بسیاری از مناطق نتایج رضایت‌بخشی ارائه کرده‌اند، اما اختلاف عملکرد بین مدل‌های منفرد و ترکیبی اغلب اندک بوده و اهمیت ارزیابی پایداری، هزینه محاسباتی و قابلیت پیاده‌سازی عملی همچنان برجسته است. پژوهش حاضر با تمرکز بر مقایسه سه مدل ترکیبی RF+LightGBM، SVM+LightGBM و RF+SVM+LightGBM تلاش دارد به این خلأ پاسخ داده و مناسب‌ترین رویکرد را برای پهنه‌بندی خطر سیلاب با در نظر گرفتن هم‌زمان دقت، سرعت و پایداری ارائه دهد.

پهنه‌بندی خطر سیل و تهیه نقشه‌های حساسیت و خطر، ابزارهای کلیدی برای مدیریت ریسک، برنامه‌ریزی کاربری اراضی، طراحی سازه‌های حفاظتی و توسعه سامانه‌های هشدار سریع محسوب می‌شوند. نقشه‌های خطر سیلاب علاوه بر آنکه در کاهش خسارات احتمالی نقش دارند، می‌توانند در ارتقاء آگاهی عمومی، سیاست‌گذاری و تصمیم‌گیری‌های کلان نیز موثر باشند. از این رو، توسعه روش‌های دقیق و کارآمد برای تولید این نقشه‌ها به یکی از اولویت‌های پژوهش‌های حوزه منابع آب و علوم محیطی تبدیل شده است. پیشرفت‌های اخیر در حوزه هوش مصنوعی و یادگیری ماشین فرصت‌های جدیدی برای تحلیل داده‌های پیچیده و پرحجم هیدرولوژیکی فراهم آورده است. الگوریتم‌هایی مانند جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM)، و مدل‌های درخت تقویت‌شده نظیر LightGBM به دلیل توانایی بالا در شناسایی روابط غیرخطی میان متغیرها و قابلیت تعمیم، به‌طور گسترده در پهنه‌بندی خطر سیلاب به کار گرفته شده‌اند. علاوه بر این، روش‌های یادگیری جمعی^۱ مانند رأی‌گیری^۲ و انباشته‌سازی^۳ و با ادغام مزایای چند الگوریتم مختلف، بهبود چشمگیری در دقت و پایداری مدل‌ها فراهم کرده‌اند.

در سال‌های اخیر مطالعات متعددی به کاربرد مدل‌های یادگیری ماشین در پهنه‌بندی خطر سیلاب پرداخته‌اند. مقایسه بین الگوریتم‌های Random Forest و LightGBM برای تولید نقشه‌های حساسیت سیل نشان داد که هر دو روش در محیط‌های مرطوب عملکرد خوبی دارند (Saber et al., 2023)؛ همچنین LightGBM نسبت به CatBoost عملکرد قابل ملاحظه‌ای دارد.

Shirmohammadi et al (۲۰۲۵) با مقایسه مدل‌هایی چون RF، LightGBM، و SVM در شمال ایران نشان دادند که مدل‌های درختی تقویت‌شده عملکرد بالاتری در نقشه‌برداری خطر دارند.

در مطالعه‌ای دیگر، (Nasiri Khiavi et al. (2024) استفاده از مدل‌های RF و SVM در حوضه گاماسیاب

³ Stacking

⁴ Deep learning

¹ Ensemble learning

² Voting

این‌رو، مناطق پایین‌تر با شیب‌های کمتر و پهنه‌های مسطح رواناب بیشتری را تولید می‌کنند و خطر سیل را افزایش می‌دهند. در این محدوده از حوضه، شیب در ۱ تا ۵۰ درصد در ۹ دسته طبقه‌بندی شد.

جهت شیب^۴

یکی از مهم‌ترین اثرات جهت شیب، میزان تابش خورشیدی دریافتی و اثرات آن مانند وقوع اقلیم محلی است. در جهات جنوبی و غربی سرعت ذوب برف به دلیل افزایش دما بیشتر است. در این مناطق برف مدت کوتاه‌تری روی زمین می‌ماند و به همین دلیل جریان زمستانی در این مناطق بیشتر و جریان چشمه یکنواخت‌تر از مناطق آبی با جهت شمال است. شیب و ذوب سریع برف در اواخر زمستان و اوایل بهار به‌طور قابل‌توجهی بر رواناب و سیل در حوضه مطالعاتی تاثیر می‌گذارد.

کاربری اراضی^۵

انواع کاربری‌های زمین بر سیل مناطق خیز مستعد سیل تاثیر می‌گذارد. میزان نفوذ آب به الگوهای استفاده از زمین بستگی دارد. مناطق پوشیده از گیاه به دلیل همبستگی منفی بین وقوع سیل و تراکم پوشش گیاهی کمتر در معرض سیل قرار دارند.

بارش^۶

بارش یک عامل مهم در تجزیه و تحلیل حساسیت سیل است. در این تحقیق، نقشه حداکثر میانگین بارندگی ماهانه با استفاده از داده‌های بارش سالانه (۱۳۸۱-۱۳۹۸) از ۵ ایستگاه باران‌سنجی حوضه با استفاده از روش درون‌یابی Kriging محاسبه شد. روش Kriging با داشتن میزان جذر میانگین مربعات کم (RMSE) برای تهیه نقشه بارندگی مطلوب تشخیص داده شد.

زمین‌شناسی^۷

زمین‌شناسی و خاک حاصل از آن تعیین‌کننده شدت و ظرفیت نفوذپذیری خاک بوده و رواناب سطحی را نیز تحت

حوزه آبخیز ناورود از جمله حوضه‌های دارای پتانسیل سیل بالا است. به این ترتیب ۶۸۳ نقطه سیل در منطقه مورد مطالعه، توسط توپوگرافی و نرم‌افزار با استفاده از بازدیدهای میدانی، نقشه توپوگرافی و تصاویر ماهواره‌ای با توجه به مناطقی مانند تپه‌ها و کوه‌ها که سیلاب قادر به پیشروی در آنجا نیست، انتخاب گردید. ۷۰ درصد داده (۴۷۸ رخداد سیل) برای آموزش مدل و ۳۰ درصد (رخداد سیل ۲۰۵) برای اعتبارسنجی مدل استفاده شد.

جهت تهیه نقشه خطر سیل با مدل‌های RF+LightGBM، LightGBM+SVM، RF+SVM+LightGBM، نرم‌افزار Anaconda3 V.2024 استفاده گردید.

۳-۲- انتخاب شاخص‌های موثر

در این پژوهش برای تهیه نقشه حساسیت به وقوع سیل ۱۰ شاخص شامل ارتفاع، شیب، جهت شیب، تراکم جریان، جهت جریان، زمین‌شناسی، کاربری اراضی، تراکم زهکشی، فاصله از آبراهه و بارش ساخته شد. در زیر به بررسی هر یک از عوامل پرداخته می‌شود.

ارتفاع^۱

پارامترهای توپوگرافی که مستقیم تحت تاثیر میزان جریان و سرعت رواناب قرار می‌گیرند، نقش مهمی در وقوع سیل دارند. با توجه به پراکندگی ارتفاع در حوضه آبریز ناورود، با درجه بالایی از نابرابری مشخص می‌شود. متوسط و زیاد زبری و اختلاف ارتفاع بیش از ۱۰۰۰ متر نشان‌دهنده پتانسیل انرژی بالای رودخانه‌ها در حوضه است. در این تحقیق، از نقشه مدل رقومی ارتفاع (DEM^۲) با وضوح ۳۰ متری استفاده شد. از DEM برای ساخت نقشه‌های شیب، جهت شیب، تراکم آبراهه نیز استفاده گردید.

شیب^۳

هر چه میزان بارندگی بیشتر باشد رواناب به دلیل شیب تند بیشتر می‌شود و در آن‌ها میزان نفوذ آب کاهش می‌یابد.

^۵ Landuse

^۶ Rainfall

^۷ Lithology

^۱ Elevation

^۲ Digital elevation model

^۳ Slope

^۴ Aspect

تاثیر قرار می‌دهد.

در افزایش خطر و شدت سیل است.

فاصله از آبراهه^۴

تراکم زهکشی به تعداد و فشردگی شبکه‌های آبراهه‌ای (طبیعی و مصنوعی) در یک منطقه اشاره دارد. تراکم زهکشی بالا می‌تواند اثرات دوگانه‌ای بر سیل‌خیزی بدارد:

۱. کاهش سیل‌خیزی اگر شبکه‌های زهکشی خوب طراحی و نگهداری شوند، می‌توانند آب باران و رواناب را به سرعت از مناطق مسکونی دور کرده و از تجمع آب و وقوع سیل جلوگیری کنند.

۲. افزایش سیل‌خیزی: اگر تراکم زهکشی بالا باشد اما شبکه‌ها به خوبی کار نکنند، یا اگر توسعه شهری باعث کاهش نفوذپذیری سطح شود، این شبکه‌ها می‌توانند به جای تخلیه، آب را به مناطق وسیع‌تری هدایت کنند و باعث سیل شوند. به طور خلاصه، تراکم بالای شبکه‌های زهکشی، اگر به خوبی کار کنند، می‌تواند به کاهش سیل‌خیزی کمک کند، اما در صورت ناکارآمدی یا طراحی نامناسب، می‌تواند خود عامل تشدید سیل باشد.

در [شکل‌های ۲ و ۳](#) پارامترهای موثر بر سیل آورده شده است.

۴-۲- مدل RF+LightGBM

مدل جنگل تصادفی (RF^۵) بر مبنای تولید مجموعه‌ای از درختان تصمیم عمل می‌کند و با رأی‌گیری میان آن‌ها، پیش‌بینی نهایی را ارائه می‌دهد. این روش به دلیل ماهیت تصادفی‌سازی در انتخاب داده‌ها و ویژگی‌ها، پایداری بالایی داشته و در برابر بیش‌برازش مقاوم است (Shirmohammadi et al., 2025).

از سوی دیگر LightGBM^۶، یک الگوریتم تقویت گرادیانی پیشرفته است که با استفاده از درخت‌های سبک و استراتژی رشد برگ‌محور، قادر به یادگیری سریع و دقیق روابط پیچیده است. (Xu et al., 2023)

نقشه زمین‌شناسی منطقه با استفاده از نقشه ۱:۲۵۰۰۰ سازمان زمین‌شناسی کشور تهیه شد. بخش عظیمی از سازندهای زمین‌شناسی منطقه را رسوبات آتشفشانی آندزیتی، سنگ‌های کرتاسه فوقانی و تمایز نیافته تشکیل می‌دهند.

جهت جریان^۱

شیب آبراهه یکی از ویژگی‌های مهم حوضه آبخیز است. شیب بیشتر آبراهه‌ها می‌تواند باعث افزایش سرعت جریان آب و در نتیجه افزایش توان حمل رسوبات و آب باشد، که این امر می‌تواند منجر به تشدید سیلاب شود. جهت جریان از طرف شمال به جنوب در جهت خطوط ارتفاعی و همچنین شمال غرب و شرق جهت‌های متفاوتی دارد.

تراکم جریان^۲

در مناطقی با تراکم زهکشی بیشتر، به دلیل فراوانی زیاد رواناب‌ها که از مناطق مختلف به یک نقطه وارد می‌شوند، امکان سرریز شدن جوی‌ها در زمان وقوع سیل بیشتر است. مناطقی که تراکم زهکشی بیشتر است، پتانسیل تولید رواناب زیاد است و هرچه تراکم زهکشی بیشتر باشد، رواناب سریع‌تر خارج می‌شود. نقشه تراکم جریان با استفاده از نقشه جهت جریان به دست آمده است.

فاصله از آبراهه^۳

فاصله از آبراهه یعنی اینکه یک مکان چقدر از رودخانه، نهر یا کانال آب طبیعی یا مصنوعی دور است. هرچه به آبراهه نزدیک‌تر باشیم، احتمال سیل‌خیزی بیشتر است. اگر آب از کانال بیرون بزند، مناطق نزدیک زودتر و شدیدتر درگیر می‌شوند. خاک نزدیک رودخانه معمولاً خیس‌تر است و آب را کمتر به خودش جذب می‌کند، پس آب روی سطح جاری می‌شود. در شهرها، آسفالت و بتن باعث افزایش رواناب می‌شوند و اگر این مناطق نزدیک رودخانه باشند، خطر سیل بیشتر است. به طور خلاصه، نزدیکی به آبراهه، عامل مهمی

^۴ Drainage density

^۵ Random forest

^۶ Light gradient boosting machine

^۱ Flow direction

^۲ Accumulation flow

^۳ Distance from waterway




Fig. 2 Factors affecting the preparation of flood susceptibility map

شکل ۲ فاکتورهای موثر بر تهیه نقشه حساسیت به سیل




Fig. 3 Factors affecting the preparation of flood susceptibility map

شکل ۳ فاکتورهای موثر بر تهیه نقشه حساسیت به سیل

می‌شود در SVM تشخیص الگوهای غیرخطی عملکرد خوبی داشته باشد (Ganjirad & Delavar., 2023). LightGBM نیز به دلیل سرعت بالا و توانایی پردازش مجموعه داده‌های حجیم، مکمل مناسبی برای SVM محسوب می‌شود. در ترکیب SVM+LightGBM از خروجی احتمالاتی SVM به عنوان ورودی فرامدل LightGBM استفاده می‌شود.

ترکیب LightGBM و RF می‌تواند هم‌زمان مزایای پایداری RF و دقت بالای LightGBM را فراهم آورد و تعادل مناسبی میان کارایی محاسباتی و عملکرد ایجاد کند.

۲-۵- مدل SVM+LightGBM

ماشین بردار پشتیبان (SVM^1) یکی از الگوریتم‌های پرکاربرد در دسته‌بندی است که با استفاده از توابع کرنل، داده‌ها را به فضای با ابعاد بالاتر نگاشت کرده و مرز تصمیم بهینه را برای جداسازی کلاس‌ها می‌یابد. این قابلیت باعث

¹ Support vector machin

۲-۶- مدل RF+SVM+LightGBM

ترکیب سه‌گانه RF، SVM و LightGBM در قالب رویکرد Stacking از نوآوری‌های این پژوهش محسوب می‌شود. در این ساختار، سه مدل پایه به‌طور موازی آموزش داده‌شده و خروجی آن‌ها به‌عنوان ورودی یک فرامدل استفاده می‌گردد. هدف از این کار بهره‌گیری هم‌زمان از مزایای هر سه الگوریتم است؛

RF برای افزایش پایداری، SVM برای شناسایی روابط غیرخطی پیچیده و LightGBM برای افزایش سرعت و دقت محاسباتی (Yang et al., 2024) این ترکیب می‌تواند بهبود اندکی در شاخص‌هایی مانند AUC و F1 ایجاد کند. هزینه محاسباتی بالاتری سه ترکیب RF+LightGBM، SVM+LightGBM و RF+SVM+LightGBM امکان بهره‌گیری از مزایای مکمل الگوریتم‌های مختلف یادگیری ماشین را فراهم می‌سازند. ترکیب RF و LightGBM به‌دلیل تعادل میان دقت و کارایی محاسباتی، گزینه‌های بهینه برای کاربردهای عملی است. ترکیب SVM و LightGBM در مواردی که روابط غیرخطی پیچیده وجود دارد مفید است، اما هزینه محاسباتی بیشتری دارد.

در نهایت ترکیب RF+SVM+LightGBM اگرچه ممکن است کمی دقت بالاتر فراهم آورد، اما به‌دلیل پیچیدگی و زمان اجرای بیشتر، تنها در کاربردهای پژوهشی یا شرایط خاص قابل توصیه است.

۲-۷- ارزیابی مدل‌ها

به‌منظور سنجش عملکرد مدل‌های ترکیبی مورد استفاده، از مجموعه‌ای جامع از شاخص‌های ارزیابی بهره گرفته شد (Sokolova & Lapalme, 2009). استفاده هم‌زمان از چند شاخص باعث می‌شود که نقاط قوت و ضعف هر مدل دقیق‌تر مشخص گردد. شاخص‌های مختلف از جمله دقت، ضریب کاپا، میانگین مربعات خطا، ریشه میانگین مربعات خطا، شاخص ماکرو و سطح زیر منحنی برای ارزیابی عملکرد مدل‌ها استفاده شدند. در ادامه، توضیح مختصری

درباره هر یک از شاخص‌ها ارائه می‌شود:

۱. دقت^۱: بیانگر نسبت تعداد پیش‌بینی‌های صحیح به کل نمونه‌ها است. هرچه مقدار Accuracy بالاتر باشد، مدل توانایی بیشتری در پیش‌بینی درست داده‌ها دارد. با این حال، در داده‌های نامتوازن، این شاخص به‌تنهایی کافی نیست (Chicco & Jurman, 2020).

۲. ضریب کاپا^۲: میزان توافق بین نتایج پیش‌بینی و مقادیر واقعی را نشان می‌دهد، اما برخلاف Accuracy، اثر شانس را نیز در نظر می‌گیرد. مقدار Kappa بالاتر از ۰.۷ نشان‌دهنده توافق قوی است (Pontius & Millones, 2011).

۳. میانگین مربعات خطا^۳: متوسط توان دوم اختلاف بین مقادیر پیش‌بینی‌شده و واقعی است. مقادیر کوچک‌تر MSE نشان‌دهنده عملکرد بهتر مدل در کاهش خطا هستند.

۴. ریشه میانگین مربعات خطا^۴: جذر مقدار MSE است و به‌دلیل داشتن همان واحد داده‌ها، تفسیرپذیری بیشتری دارد (Willmott & Matsuura, 2005).

۵. شاخص F1 (F1-Score: Macro و Weighted): شاخص F1 یک معیار ترکیبی است که تعادلی بین دقت و یادآوری برقرار می‌کند. این شاخص به‌ویژه در مسائلی که کلاس‌ها نامتوازن هستند بسیار مفید است (Willmott & Matsuura, 2005).

۶. دقت^۵: دقت نشان‌دهنده نسبت تعداد پیش‌بینی‌های صحیح کلاس مثبت به کل پیش‌بینی‌های مدل برای آن کلاس مثبت است. به عبارت دیگر، از بین تمام مناطقی که مدل آن‌ها را سیل‌زده پیش‌بینی کرده، چه نسبتی واقعا سیل‌زده بوده‌اند.

۷. یادآوری^۶: یادآوری (که به آن حساسیت نیز گفته می‌شود) نسبت تعداد پیش‌بینی‌های صحیح

^۴ RMSE

^۵ Precision

^۶ Recall

^۱ Accuracy

^۲ Kappa

^۳ MSE

سیلاب دارند. مدل ترکیبی RF+SVM+LightGBM با AUC برابر ۰/۹۴ اندکی بهتر از دو مدل دیگر عمل کرده است، درحالی‌که اختلاف میان سه مدل بسیار جزئی است. این موضوع نشان‌دهنده توانایی بالا و رقابت‌پذیری هر سه مدل است.

در **شکل ۵** نمودار ستونی مقایسه عملکرد مدل‌ها نشان داده شده است. همان‌طور که دیده می‌شود، مدل سه‌گانه RF+SVM+LightGBM در شاخص ROC-AUC کمی بالاتر از سایر مدل‌ها قرار دارد.

مدل SVM+LightGBM نیز عملکرد نزدیکی به مدل سه‌گانه دارد و از مدل RF+LightGBM اندکی بهتر است. در **شکل ۶** نمودار ROC مقایسه‌ای سه مدل ترکیبی نشان داده شده است. همان‌طور که منحنی‌ها نشان می‌دهند، مدل RF+SVM+LightGBM بالاترین AUC را داشته و بهترین توانایی در تشخیص درست مثبت‌ها و منفی‌ها را ارائه کرده است. این موضوع اهمیت استفاده از روش‌های Stacking چندمدلی را در بهبود عملکرد نشان می‌دهد.

کلاس مثبت (مناطق سیل‌زده) به کل نمونه‌های واقعی آن کلاس مثبت را نشان می‌دهد.
۸. مساحت زیر منحنی ROC^۱: معیاری کلی از قدرت جداسازی مدل است. AUC نزدیک به نشان‌دهنده عملکرد عالی مدل در تفکیک کلاس‌هاست (Powers, 2011).

۳- نتایج و بحث

نتایج مدل‌های ترکیبی ارائه شده RF+LightGBM، RF+SVM+LightGBM و LightGBM+SVM تحلیل می‌شوند. تعیین مهم‌ترین و موثرترین فاکتورهای تاثیرگذار بر سیلاب جهت انجام مدل‌سازی بسیار ضروری است. در این پژوهش اولویت‌بندی فاکتورهای موثر بر سیلاب در حوزه آبریز ناورود در **شکل ۴** نشان داده شده است. نتایج نشان داد که به ترتیب بارش، رقوم ارتفاعی تراکم زهکشی، جهت شیب بیشترین تاثیر را در تهیه نقشه حساسیت به وقوع سیل دارند. در **جدول ۱** شاخص‌های ارزیابی عملکرد مدل‌ها آورده شده است. **این جدول** نشان می‌دهد که هر سه مدل عملکرد بالایی در پهنه‌بندی خطر




Fig. 4 Influential parameter in the models

شکل ۴ پارامتر تاثیرپذیر در مدل‌ها

¹ Area under the receiver operating characteristic curve - AUC

جدول ۱ مقایسه شاخص‌های ارزیابی عملکرد مدل‌ها

Table 1 Comparison of Model Performance Evaluation Metrics

Model	Accuracy	Kappa	MSE	RMSE	F1-macro	F1-weighted	Precision	Recall	ROC-AUC
RF+ LightGBM	0.88	0.75	0.102	0.319	0.86	0.86	0.86	0.87	0.93
SVM+ LightGBM	0.89	0.76	0.098	0.313	0.87	0.87	0.87	0.88	0.94
RF+SVM+ LightGBM	0.89	0.76	0.097	0.311	0.87	0.87	0.87	0.88	0.94

پهنه‌بندی خطر سیلاب باشند. مدل RF+LightGBM به دلیل ماهیت ساده‌تر و سرعت بالاتر، گزینه مناسبی برای کاربردهای عملی محسوب می‌شود.

مدل SVM+LightGBM توانایی بالاتری در تشخیص الگوهای غیرخطی داشته و در شرایطی که روابط پیچیده میان متغیرها وجود دارد عملکرد بهتری نشان می‌دهد. مدل RF+SVM+LightGBM اگرچه هزینه محاسباتی بیشتری دارد، اما اندکی دقت بالاتر به‌ویژه در شاخص AUC ارائه می‌دهد. در مقایسه شاخص‌های مختلف، مشاهده شد که مقدار Accuracy برای هر سه مدل نزدیک به ۸۹٪ است و تفاوت قابل‌توجهی ندارد. این نشان‌دهنده کارایی مناسب همه مدل‌ها در شناسایی درست نمونه‌ها است. با این حال، تفاوت اصلی در شاخص ROC-AUC آشکار می‌شود؛ جایی که مدل سه‌گانه RF+SVM+LightGBM اندکی بالاتر است و نشان می‌دهد توانایی بهتری در افتراق میان رده‌ها دارد. نتایج ماتریس اغتشاش نیز موید همین موضوع است. خطاهای طبقه‌بندی در مدل RF+SVM+LightGBM به حداقل رسیده‌اند و بیشتر نمونه‌ها به‌درستی پیش‌بینی شده‌اند. این امر برای کاربردهای عملی مانند مدیریت بحران و برنامه‌ریزی شهری اهمیت زیادی دارد، زیرا خطا در پیش‌بینی مناطق پرخطر می‌تواند خسارات جانی و مالی به همراه داشته باشد.

به‌طور کلی، می‌توان نتیجه گرفت که استفاده از ترکیب چند الگوریتم در قالب Stacking می‌تواند موجب افزایش دقت و پایداری مدل‌های پیش‌بینی سیلاب شود. با این حال، انتخاب مدل مناسب باید براساس توازن میان دقت، زمان اجرا و منابع محاسباتی در هر پروژه خاص انجام گیرد.




Fig. 5 Comparison of model performance metrics

شکل ۵ مقایسه شاخص‌های عملکرد مدل‌ها




Fig. 6 ROC Curve comparison

شکل ۶ نمودار ROC برای مقایسه مدل‌ها

در شکل ۷ ماتریس اغتشاش برای مدل سه‌گانه RF+SVM+LightGBM نشان داده شده است. همان‌طور که مشخص است، بیشتر نمونه‌ها به‌درستی طبقه‌بندی شده‌اند. این نشان می‌دهد که مدل علاوه بر دقت بالا، توانایی مناسبی در شناسایی هر دو کلاس مناطق پرخطر و کم‌خطر سیلاب دارد.

نتایج این پژوهش نشان داد که مدل‌های ترکیبی مبتنی بر یادگیری ماشین می‌توانند ابزارهای کارآمدی برای




Fig. 9 Flood susceptibility map produced by SVM+LightGBM model

شکل ۹ نقشه حساسیت سیل تولیدشده توسط مدل SVM+LightGBM




Fig. 7 Confusion matrix-RF+SVM+LightGBM

شکل ۷ ماتریس اغتشاش مدل RF+SVM+LightGBM




Fig. 10 Flood susceptibility map produced by RF+SVM+LightGBM model

شکل ۱۰ نقشه حساسیت سیل تولیدشده توسط مدل RF+SVM+LightGBM




Fig. 8 Flood susceptibility map produced by RF+LightGBM model

شکل ۸ نقشه حساسیت سیل تولیدشده توسط مدل RF+LightGBM

با مطالعات (Chezgi et al. (2024) مطابقت دارد. در مناطق جنگلی که اکنون توسعه کشاورزی و مسکونی یافته‌اند با کاهش پوشش جنگلی موجب شده که این مناطق در طبقه حساسیت زیاد قرار بگیرند که با مطالعات Wahba et al. (2024) مطابقت دارد. در مناطق پایین‌دست به دلیل کاهش سطح اراضی جنگلی و تغییر کاربری‌های شدید صورت گرفته در چند سال اخیر که سبب کاهش اراضی جنگلی و افزایش اراضی کشاورزی و مسکونی شده احتمال وقوع خسارات را افزایش داده است. از طرف دیگر کاهش فاصله با حریم اصلی رودخانه و در معرض قرارگرفتن املاک، اراضی و افراد از دیگر عوامل موثر در افزایش خسارت در مواقع سیلابی در این مناطق بوده است.

نقشه‌های احتمال وقوع سیل با استفاده از سه مدل تهیه شد و هرکدام این نقشه براساس مطالعات قبلی به ۴ طبقه حساسیت شامل: کم، متوسط، زیاد و خیلی زیاد تقسیم گردید. در **شکل‌های ۸ تا ۱۰** نقشه خطر سیلاب برای هر سه مدل نشان داده شده است.

هر چه ارتفاع، شیب و فاصله از رودخانه بیشتر باشد احتمال سیل‌گیری کاهش پیدا می‌کند و در طبقه حساسیت کم قرار گیرد که با مطالعات (Farhadi, et al. (2021) مطابقت دارد. در مناطقی که پوشش جنگلی کمتری وجود دارد و مناطقی که به مرتع تبدیل یافته‌اند و با افزایش اراضی کشاورزی در طبقه حساسیت خطر متوسط قرارگرفته‌اند که

۴- نتیجه‌گیری

در این پژوهش با هدف بهبود دقت پهنه‌بندی خطر سیلاب، مدل‌های ترکیبی SVM+LightGBM، RF+LightGBM و LightGBM مبتنی بر الگوریتم‌های یادگیری ماشین توسعه و ارزیابی شدند. نتایج نشان داد که هر سه مدل از دقت بالایی برخوردارند و مقدار AUC آن‌ها بالاتر از ۰/۹۳ است که بیانگر توانایی قابل‌توجه در تفکیک مناطق پرخطر و کم‌خطر است. ترکیب SVM با مدل‌های درختی RF و LightGBM منجر به افزایش اندک در دقت شد (AUC≈۰/۹۴)، اما این بهبود از نظر آماری معنادار نبوده و هزینه‌های محاسباتی بیشتری را به همراه داشت. در مقابل، ترکیب RF+LightGBM علیرغم ساختار ساده‌تر و سرعت بالاتر، عملکردی مشابه با مدل‌های پیچیده‌تر ارائه داد و

به‌عنوان گزینه بهینه برای کاربردهای عملی پیشنهاد می‌شود. به‌طور کلی، یافته‌های این پژوهش تایید می‌کند که استفاده از مدل‌های ترکیبی می‌تواند به ارتقای دقت پهنه‌بندی خطر سیلاب کمک کند، اما پیچیده‌تر کردن ساختار مدل لزوماً منجر به بهبود قابل‌ملاحظه در نتایج نمی‌شود. براین اساس، انتخاب مدل باید با در نظر گرفتن دقت، پایداری، سرعت محاسباتی و امکان پیاده‌سازی عملی صورت گیرد.

می‌توان نتیجه گرفت که ترکیب RF+LightGBM به دلیل تعادل میان دقت و کارایی محاسباتی، به‌عنوان رویکرد پیشنهادی برای توسعه سامانه‌های هشدار سریع و مدیریت خطر سیلاب در مقیاس‌های منطقه‌ای توصیه می‌شود.

5- List of symbols

SVM	Support vector machine
RF	Random forest
LightGBM	Light gradient boosting machine

Acknowledgments

We would like to express our deepest gratitude to the Regional Water Organization of Gilan Province for their valuable cooperation and assistance in preparing this article.

Credit Authorship Contribution Statement

Conceptualization, M.Y. and A.A.; Methodology, M.Y.; Software, M.Y.; data analysis, M.Y. and A.A.; Writing-Original Draft Preparation, M.Y.; Writing-Review and Editing, A.A.; Supervision, A.A.

All authors have read and agreed to the published version of the manuscript.

Funding

This research received no external funding.

Data Availability Statement

Some or all of the data, models, or codes that support the findings of this study are available from the corresponding author upon reasonable request.

Conflicts of Interest

The authors declare no conflict of interest.

References

- Alam, M. G., Li, J. (2025). A novel framework embedding Bayesian-optimized ensemble machine learning and explainable artificial intelligence (XAI) to improve flood prediction in complex watersheds. *Environmental and Sustainability Indicators*, 27, 100760. <https://doi.org/10.1016/j.indic.2025.100760>
- Chicco, D., & Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics*, 21(1):6. <https://doi.org/10.1186/s12864-019-6413-7>
- Chezgi, J. Poyan, S. (2024). Determining Flood-Prone Areas Using Machine Learning Models in the Shahrestank Watershed Area of Khosf City, Iran-Watershed Management Science & Engineering, 17(63), <https://doi.org/10.22034/17.63.38>.
- Ganjirad, A., & Delavar, M. (2023). Flood Risk Mapping Using Random Forest and Support Vector Machine. *ISPRS Annals of the Photogrammetry, Remote Sensing Spatial Inf. Sci.*, X-4/W1-2022, 201–208. <https://doi.org/10.5194/isprs-annals-X-4-W1-2022-201-2023>
- Farhadi, H. & Najafzadeh, M. (2021). Flood Risk Mapping by Remote Sensing Data and Random Forest Technique. *Water*, 13(21), 3115, <https://doi.org/10.3399/w13213115>
- Nasiri Khiavi, M., et al. (2024). Enhancing flood mapping through ensemble machine learning in the Gamasyab watershed, Western Iran.

- Environmental Monitoring and Assessment. Environmental Science and Pollution Research 31(38):50427-50442. <https://doi.org/10.1007/s11356-024-34501-5>
- Pontius, R. G., & Millones, M. (2011). Death to Kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment. International Journal of Remote Sensing / related discussion, 32(15):4407-4429. <https://doi.org/10.1080/01431161.2011.552923>
- Powers, D. M. W. (2011). Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation. Journal of Machine Learning Technologies, 2(1), 37–63. <https://doi.org/10.48550/arXiv.2010.16061>
- Saber, M., Boulmaiz, T., Guermoui, M., Abdrabo, K. I., Kantoush, S. A., Sumi, T., Mabrouk, E. (2023). Enhancing flood risk assessment through integration of ensemble learning approaches and physical-based hydrological modeling (Case study: Vu Gia-Thu Bon basin, Vietnam). Geomatics, Natural Hazards and Risk, 14(1). <https://doi.org/10.1080/19475705.2023.2203798>.
- Shirmohammadi, M., Pirasteh, S., Shahabi, H., Chen, W. (2025).: Flood risk mapping and performance efficiency evaluation of machine learning algorithms: Best practice in northern Iran, Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci., XLVIII-G-2025, 1347–1352. <https://doi.org/10.5194/isprs-archives-XLVIII-G-2025-1347-2025>.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. Journal of Information Processing and Management, 45(4):427-437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. Climate Research, 30(1):79-82. <https://doi.org/10.3354/cr030079>
- Wahba, M., adwa Essam, R. El-Rawy, M. Al-Arifi, N. Abdalla, F. M. Elsadek, W. (2024). Forecasting of flash flood susceptibility mapping using random forest regression model and geographic information systems. ScienceDirect, 10(3). <https://doi.org/10.1016/j.heliyon.2024.e33982>
- Xu, K., Han, Z., Xu, H., Bin, L. (2023). Rapid Prediction Model for Urban Floods Based on a Light Gradient Boosting Machine Approach and Hydrological-Hydraulic Model. International Journal of Disaster Risk Science, 14, 79–97. <https://doi.org/10.1007/s13753-023-00465-2>.
- Yang, H., Wang, J., Liu, Y., & Zhao, X. (2024). Advancing flood susceptibility modeling using stacking ensemble machine learning: A multi-model approach. Journal of Geographical Sciences, 34(6), 1034–1050. <https://doi.org/10.1007/s11442-024-2259-1>.
- Zhang, Y., et al. (2025). High-resolution flood susceptibility mapping using remote sensing and LightGBM. Natural Hazards.