



## ORIGINAL RESEARCH PAPER

## Development of Optimized Explainable Machine Learning Models for Preparing Multi-Hazard Susceptibility Maps of Flood, Landslide, and Land Subsidence (Case Study: Caspian Sea Coast)

K. Kheirkhah<sup>1</sup>, AA. AleSheikh<sup>1, \*</sup>, A. Jafari<sup>1</sup>, F. Rezaie<sup>1</sup>, M. Panahi<sup>2</sup><sup>1</sup> Department of Geospatial Information Systems, Faculty of Surveying Engineering, K. N. Toosi University of Technology, Tehran, Iran<sup>2</sup> Department of Physical Geography and Bolin Centre for Climate Research, Stockholm University, Stockholm, Sweden

## ABSTRACT

Received: 30 December 2025  
Reviewed: 14 March 2026  
Revised: 10 May 2026  
Accepted: 06 June 2026

## KEYWORDS:

Multi-hazard susceptibility  
Support Vector Regression  
Grey Wolf Optimizer Explainable Machine Learning  
Northern Provinces of Iran

\* Corresponding author

✉ alesheikh@kntu.ac.ir

☎ (+9821) 88786212

**Background and Objectives:** Iran's northern provinces (Golestan, Mazandaran, and Gilan) lie along the Caspian Sea and combine humid climate, steep Alborz topography, intensive groundwater extraction for agriculture, and rapid land-use change, making them simultaneously exposed to floods, landslides, and land subsidence. Despite this co-occurrence, most prior studies have addressed each hazard in isolation, providing limited insight into where these threats overlap spatially and how they should be jointly managed at the regional scale. Existing susceptibility models often rely on single machine learning algorithms without systematic hyperparameter tuning and treat their predictions as opaque outputs, limiting their value for evidence-based decision-making and undermining stakeholder trust. This research aims to develop an optimized and interpretable framework that produces joint susceptibility maps for all three hazards across this region, supporting integrated risk planning and informed land-use policy.

**Methods:** A hybrid model combining Support Vector Regression with the Two-phase Mutation Grey Wolf Optimizer (SVR-TMGWO) was built separately for each hazard. Twenty years of recorded flood and landslide events (2000–2020) were compiled from the Geological Survey of Iran and the national watershed-management authority, while subsidence locations were derived from Sentinel-1 InSAR analyses. Non-event points were generated randomly outside a 2000-metre buffer around recorded events at a 1:1 ratio to preserve class balance, and the dataset was partitioned into 70% training and 30% testing within K-means clusters (with the optimal K determined via Gap and Silhouette analyses) so that the feature-space distribution was balanced across both subsets. Eighteen conditioning factors spanning topographic, hydrological, environmental, anthropogenic, and soil-physical variables were prepared for each pixel. The TMGWO algorithm simultaneously tuned the three SVR hyperparameters (C,  $\epsilon$ ,  $\gamma$ ) for each hazard, producing distinct configurations that reflect the differing physics of each process. Model accuracy was evaluated using AUC-ROC, RMSE,  $R^2$ , and adjusted  $R^2$  on independent test data. To overcome the black-box limitation of machine learning, Shapley Additive Explanations (SHAP) were computed at both global and local scales, exposing the contribution of each conditioning factor to the prediction at the regional level and at individual locations. Finally, the three single-hazard maps were combined into an eight-class multi-hazard map identifying areas of single, dual, and triple hazard overlap.

**Findings:** TMGWO consistently improved test-phase AUC-ROC over the base SVR model, reaching 0.8404 for flood, 0.9329 for landslide, and 0.9642 for subsidence, while narrowing the training-test gap and indicating reduced overfitting compared with the unoptimized baseline. SHAP identified elevation as the leading driver across all three hazards but revealed contrasting secondary controls per process. The multi-hazard map showed that triple-overlap zones were spatially restricted and concentrated along the mountain-plain transition.

**Conclusion:** The proposed SVR-TMGWO framework, combined with SHAP interpretability, produced spatially explicit and physically meaningful susceptibility maps for three coexisting hazards in northern Iran. The resulting eight-class multi-hazard product highlights priority areas for integrated land-use planning, infrastructure protection, and early-warning prioritisation, while the SHAP outputs make the model's reasoning transparent to non-expert stakeholders. Future research should incorporate temporal dynamics through multi-temporal InSAR and climate projections, compare deep learning alternatives such as convolutional neural networks, and extend the framework to full risk assessment by including exposure and vulnerability components.



NUMBER OF REFERENCES

38



NUMBER OF FIGURES

14



NUMBER OF TABLES

3

## مقاله پژوهشی

## توسعه مدل‌های یادگیری ماشین توضیح‌پذیر بهینه‌سازی شده به منظور تهیه نقشه حساسیت چندمخاطره‌ای سیل، زمین‌لغزش و فرونشست زمین (مطالعه موردی: سواحل دریای خزر)

کیمیا خیرخواه<sup>۱</sup>، علی اصغر آل شیخ<sup>۱\*</sup>، علی جعفری<sup>۱</sup>، فاطمه رضائی<sup>۱</sup>، مهدی پناهی<sup>۲</sup><sup>۱</sup> گروه سیستم‌های اطلاعات مکانی، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران<sup>۲</sup> گروه جغرافیای فیزیکی و مرکز تحقیقات اقلیمی بولین، دانشگاه استکهلم، استکهلم، سوئد

## چکیده

**پیشینه و اهداف:** استان‌های شمالی ایران (گلستان، مازندران و گیلان) در امتداد دریای خزر قرار گرفته‌اند و ترکیب آب‌وهوای مرطوب، توپوگرافی شیب‌دار البرز، برداشت بی‌رویه آب زیرزمینی برای کشاورزی و تغییر سریع کاربری اراضی موجب می‌شود این منطقه به‌طور هم‌زمان در معرض سیل، زمین‌لغزش و فرونشست زمین قرار گیرد. با وجود این هم‌زمانی، بیشتر مطالعات پیشین هر یک از مخاطرات را به‌صورت مجزا بررسی کرده‌اند و بینش محدودی درباره مکان‌های همپوشانی فضایی این تهدیدها و چگونگی مدیریت مشترک آن‌ها در مقیاس منطقه‌ای ارائه کرده‌اند. مدل‌های حساسیت موجود اغلب بر الگوریتم‌های یادگیری ماشین منفرد و بدون تنظیم سیستماتیک فرآیندها متکی هستند و خروجی‌های آن‌ها به‌عنوان جعبه‌سیاه در نظر گرفته می‌شود، که این موضوع کاربرد آن‌ها را در تصمیم‌گیری مبتنی بر شواهد محدود کرده و اعتماد ذی‌نفعان را تضعیف می‌کند. هدف این پژوهش، توسعه یک چارچوب بهینه‌سازی شده و تفسیرپذیر برای تهیه نقشه‌های حساسیت توأمان هر سه مخاطره در این منطقه و پشتیبانی از برنامه‌ریزی یکپارچه ریسک و سیاست‌گذاری آگاهانه کاربری اراضی است.

**روش‌ها:** یک مدل ترکیبی شامل رگرسیون بردار پشتیبان به همراه الگوریتم بهینه‌سازی گرگ خاکستری با جهش دومرحله‌ای (SVR-TMGWO) به‌صورت جداگانه برای هر مخاطره ساخته شد. اطلاعات رخدادهای سیل و زمین‌لغزش طی یک دوره بیست‌ساله (۲۰۰۰ تا ۲۰۲۰) از سازمان زمین‌شناسی و اکتشافات معدنی ایران و سازمان منابع طبیعی و آبخیزداری کشور گردآوری شد، و موقعیت نقاط فرونشست از تحلیل‌های تداخل‌سنجی راداری Sentinel-۱ استخراج گردید. نقاط عدم رخداد به‌صورت رندوم در خارج از بافر ۲۰۰۰ متری اطراف رخدادهای ثبت‌شده و با نسبت ۱:۱ تولید شدند تا توازن دسته‌ای حفظ شود، و سپس داده‌ها در درون خوشه‌های K-means که مقدار بهینه K از طریق تحلیل‌های Silhouette و Gap تعیین شد) به نسبت ۷۰٪ آموزش و ۳۰٪ آزمون تقسیم گردیدند تا توزیع داده‌ها در فضای ویژگی بین دو زیرمجموعه متوازن باقی بماند. هجده عامل مؤثر شامل متغیرهای توپوگرافی، هیدرولوژیکی، محیطی، انسان‌ساخت و ویژگی‌های فیزیکی خاک برای هر پیکسل آماده‌سازی شد. الگوریتم TMGWO سه فرآیند SVR (یعنی C، ε و γ) را به‌صورت هم‌زمان برای هر مخاطره تنظیم کرد و پیکربندی‌های متمایزی متناسب با فیزیک هر فرآیند به‌دست داد. دقت مدل با استفاده از شاخص‌های AUC-ROC، RMSE، R<sup>2</sup> و R<sup>2</sup> تعدیل‌شده روی داده‌های آزمون مستقل ارزیابی شد. به‌منظور غلبه بر محدودیت جعبه‌سیاه بودن یادگیری ماشین، مقادیر شپلی (SHAP) در دو سطح جهانی و محلی محاسبه شد تا سهم هر عامل مؤثر در پیش‌بینی، هم در سطح منطقه‌ای و هم در موقعیت‌های منفرد، آشکار گردد. در پایان، سه نقشه حساسیت تک‌مخاطره‌ای در قالب یک نقشه چندمخاطره‌ای هشت‌طبقه‌ای تلفیق شدند که پهنه‌های با همپوشانی یگانه، دوگانه و سه‌گانه را مشخص می‌کند.

تاریخ دریافت: ۰۹ دی ۱۴۰۴

تاریخ داوری: ۲۳ اسفند ۱۴۰۴

تاریخ اصلاح: ۲۰ اردیبهشت ۱۴۰۵

تاریخ پذیرش: ۱۶ خرداد ۱۴۰۵

واژگان کلیدی:

حساسیت چندمخاطره‌ای

رگرسیون بردار پشتیبان

الگوریتم گرگ خاکستری یادگیری ماشین

توضیح‌پذیر استان‌های شمالی ایران

\* نویسنده مسئول

alesheikh@kntu.ac.ir

021-88786212

**یافته‌ها:** الگوریتم TMGWO به‌طور پیوسته مقدار AUC-ROC را در مرحله آزمون نسبت به مدل پایه SVR بهبود بخشید و به ۰/۸۴۰۴ برای سیل، ۰/۹۳۲۹ برای زمین‌لغزش و ۰/۹۶۴۲ برای فرونشست رسید، و در عین حال فاصله میان مرحله آموزش و آزمون را کاهش داد که نشان‌دهنده کنترل بیش‌برازش در مقایسه با مدل پایه بهینه‌نشده است. تحلیل SHAP ارتفاع را به‌عنوان عامل غالب در هر سه مخاطره شناسایی کرد، اما عوامل ثانویه متفاوتی برای هر فرآیند آشکار ساخت. نقشه چندمخاطره‌ای نشان داد که پهنه‌های با همپوشانی سه‌گانه از نظر فضایی محدود و در نواحی انتقالی میان کوهستان و دشت متمرکز هستند.

**نتیجه‌گیری:** چارچوب پیشنهادی SVR-TMGWO در ترکیب با تفسیرپذیری مبتنی بر SHAP، نقشه‌های حساسیت فضایی صریح و از نظر فیزیکی معنادار را برای سه مخاطره هم‌زمان در شمال ایران تولید کرد. نقشه چندمخاطره‌ای هشت‌طبقه‌ای حاصل، مناطق اولویت‌دار را برای برنامه‌ریزی یکپارچه کاربری اراضی، حفاظت از زیرساخت‌ها و اولویت‌بندی هشدار اولیه مشخص می‌کند، در حالی که خروجی‌های SHAP استدلال مدل را برای ذی‌نفعان غیرمتخصص شفاف می‌سازد. در پژوهش‌های آتی، گنجاندن پویایی‌های زمانی از طریق تحلیل‌های چندزمانه InsAR و سناریوهای اقلیمی، مقایسه با گزینه‌های یادگیری عمیق مانند شبکه‌های عصبی پیچشی، و گسترش چارچوب به ارزیابی کامل ریسک از طریق در نظر گرفتن مؤلفه‌های در معرض‌قرارگرفتنی و آسیب‌پذیری توصیه می‌شود.

## مقدمه

مخاطرات طبیعی مانند سیل، زمین‌لغزش و فرونشست زمین از مهم‌ترین پدیده‌هایی هستند که پایداری اجتماعی، اقتصادی و زیست‌محیطی جوامع را به طور جدی تهدید می‌کنند و پیامدهای گسترده‌ای بر زیرساخت‌ها و سکونتگاه‌های انسانی دارند [۱، ۲]. تأثیر این مخاطرات می‌تواند ناشی از ترکیب عوامل طبیعی و فعالیت‌های انسانی باشد و بروز آن‌ها در بسیاری از مناطق، خسارات اقتصادی و جانی قابل توجهی ایجاد می‌کند [۳]. با توجه به افزایش وقوع و شدت این پدیده‌ها طی سال‌های اخیر، ارزیابی دقیق حساسیت و ریسک آن‌ها ضروری بوده و نقش مهمی در برنامه‌ریزی کاربری زمین و مدیریت بحران ایفا می‌کند [۴]. در این راستا، استفاده از فناوری‌های نوین مانند یادگیری ماشین و سامانه‌های اطلاعات جغرافیایی، امکان تحلیل دقیق‌تر و پیش‌بینی قابل‌اعتمادتر رفتار این مخاطرات را فراهم می‌کند [۵].

پیامدهای خسارات ناشی از این سه مخاطره دارای ماهیت‌های متفاوتی هستند و هر یک به شکل متفاوتی مناطق تحت تأثیر را دست‌خوش تغییر قرار می‌دهند. رانش زمین یکی از خطرناک‌ترین رخداد‌های زمین‌شناسی است که علاوه بر ایجاد پیامدها و حوادث ثانویه، می‌تواند آسیب‌های اجتماعی گسترده و زیان‌های اقتصادی قابل توجهی به‌جا بگذارد [۶]. علاوه بر آن، سیلاب‌ها در نواحی شهری و حوزه‌های آبخیز، با تخریب گسترده زیرساخت‌های عمرانی، نابودی معیشت ساکنان و جابجایی جمعیت، چالش‌های مدیریتی سنگینی را ایجاد می‌کنند و زندگی ده‌ها هزار نفر را به صورت سالانه تحت تأثیر قرار می‌دهند [۱، ۵، ۷]. در نهایت، فرونشست زمین اگرچه پدیده‌ای تدریجی و با شروعی آرام است، اما با ایجاد شکاف در ابنیه، آسیب به خطوط انتقال انرژی و آب، و کاهش دائمی ظرفیت ذخیره آب در سفره‌های زیرزمینی، خسارات اقتصادی بلندمدت و اغلب جبران‌ناپذیری را به ساختار شهری و کشاورزی تحمیل می‌کند [۲، ۵].

نقشه‌های حساسیت به‌عنوان مرحله اولیه برای تشخیص و تعیین نواحی مستعد وقوع مخاطرات طبیعی مورد استفاده قرار می‌گیرد [۶، ۸]. در تهیه نقشه‌های حساسیت، ضروری است که مخاطرات به‌صورت یک سامانه مرتبط و متعامل بررسی شوند، نه به شکل مجزا؛ چراکه میان آن‌ها ارتباط متقابل وجود دارد و وقوع یکی می‌تواند منجر به فعال‌سازی یا تشدید دیگری شود [۱، ۸]. در این میان، پیشرفت روش‌های داده‌محور به‌ویژه الگوریتم‌های یادگیری ماشین، امکان تحلیل روابط پیچیده میان عوامل محیطی و وقوع مخاطرات را فراهم کرده و باعث شده است که این روش‌ها به‌طور گسترده در تهیه نقشه‌های حساسیت مورد استفاده قرار گیرند [۶، ۹]. برای نمونه، یوسفی و همکاران (۲۰۲۰) در یک مطالعه چندمخاطره‌ای، احتمال وقوع بهممن، زمین‌لغزش، آتش‌سوزی جنگلی، فرونشست زمین و سیلاب با استفاده از مدل‌های SVM (Support Vector Machine)، Boosted Regression BRT، Tree و (Generalized Linear Model) GLM برآورد شد و نتایج نشان داد که برای برخی از مخاطرات، مدل SVM از دقت بالاتری برخوردار است، در حالی که GLM و FDA (Flexible Discriminant Analysis) در برخی سناریوها عملکرد بهتری داشته‌اند [۲]. در پژوهشی دیگر انجام شده توسط لیو و همکاران (۲۰۲۱)، حساسیت زمین‌لغزش با استفاده از ترکیب SVR و الگوریتم‌های GWO (Grey Wolf Optimization) و FA (Firefly Algorithm) بررسی شده و نتایج نشان داد که مدل ترکیبی SVR-GWO با AUC-ROC برابر ۰/۸۵۴ عملکرد بهتری نسبت به SVR-FA (Characteristic Curve) با AUC-ROC برابر ۰/۸۳۸ و مدل SVR ساده (با AUC-ROC برابر با ۰/۸۱۸) داشته است [۶]. همچنین پورقاسمی و همکاران (۲۰۲۰) در مطالعه‌ای مربوط به استان فارس، ابتدا عوامل مؤثر بر سیلاب، زمین‌لغزش و آتش‌سوزی جنگلی را با الگوریتم Boruta اولویت‌بندی و سپس نقشه‌های حساسیت این مخاطرات را با استفاده از مدل جنگل تصادفی (RF) تولید کردند و طبق نتایج اعتبارسنجی، مقادیر AUC-

بیش‌برازش جلوگیری شود. همچنین به منظور افزایش شفافیت مدل و غلبه بر ماهیت جعبه‌سیاه آن، تحلیل‌های SHAP (SHapley Additive SHAP) exPlanations در سطوح جهانی و محلی به کار گرفته شد. در نهایت، نقشه‌های حساسیت هر مخاطره به صورت جداگانه تولید و پس از تحلیل، در قالب یک نقشه جامع چندمخاطره‌ای تلفیق شدند.

### روش تحقیق

چارچوب عملیاتی این پژوهش جهت پهنه‌بندی حساسیت چندمخاطره‌ای، مطابق با شکل ۱ در شش گام اصلی سازماندهی شده است. در گام نخست، شناسایی ویژگی‌ها و عوامل موثر بر وقوع مخاطرات بر اساس مرور پیشینه تحقیق و تحلیل داده‌های رستری منطقه مورد مطالعه انجام گرفت. در گام دوم، تهیه مجموعه داده‌ها با استفاده از نقاط واقعه (مستعد) و نقاط بی‌خطر صورت پذیرفت. پس از شبکه‌بندی منطقه، داده‌ها به صورت تصادفی به دو دسته آموزش (۷۰٪) جهت برازش مدل و ارزیابی (۳۰٪) برای اعتبارسنجی تقسیم شدند. گام سوم به پهنه‌سازی فراابتکاری اختصاص یافته است؛ در این مرحله، الگوریتم پهنه‌ساز (TMGWO) با جستجو در فضای پاسخ، بهترین ترکیب از فراپارامترها و ویژگی‌های ورودی را برای تولید مدل SVR انتخاب می‌کنند. در گام چهارم، ارزیابی مدل پهنه (SVR-TMGWO) از طریق معیارهای آماری و اعتبارسنجی مکانی انجام می‌شود تا دقت مدل در پیش‌بینی مخاطرات تایید گردد. گام پنجم با هدف رفع ماهیت «جعبه سیاه» مدل‌های یادگیری ماشین، به توضیح‌پذیری مدل (XAI: Explainable Artificial Intelligence) با استفاده از رویکرد SHAP می‌پردازد تا سهم و اهمیت هر یک از متغیرها در سطوح محلی و جهانی مشخص شود. در نهایت، در گام ششم (ترکیب نقشه‌ها)، نقشه‌های حساسیت تک‌مخاطره‌ای با یکدیگر تلفیق شده و نقشه نهایی حساسیت چندمخاطره‌ای منطقه برای شناسایی کانون‌های بحرانی تولید می‌گردد.

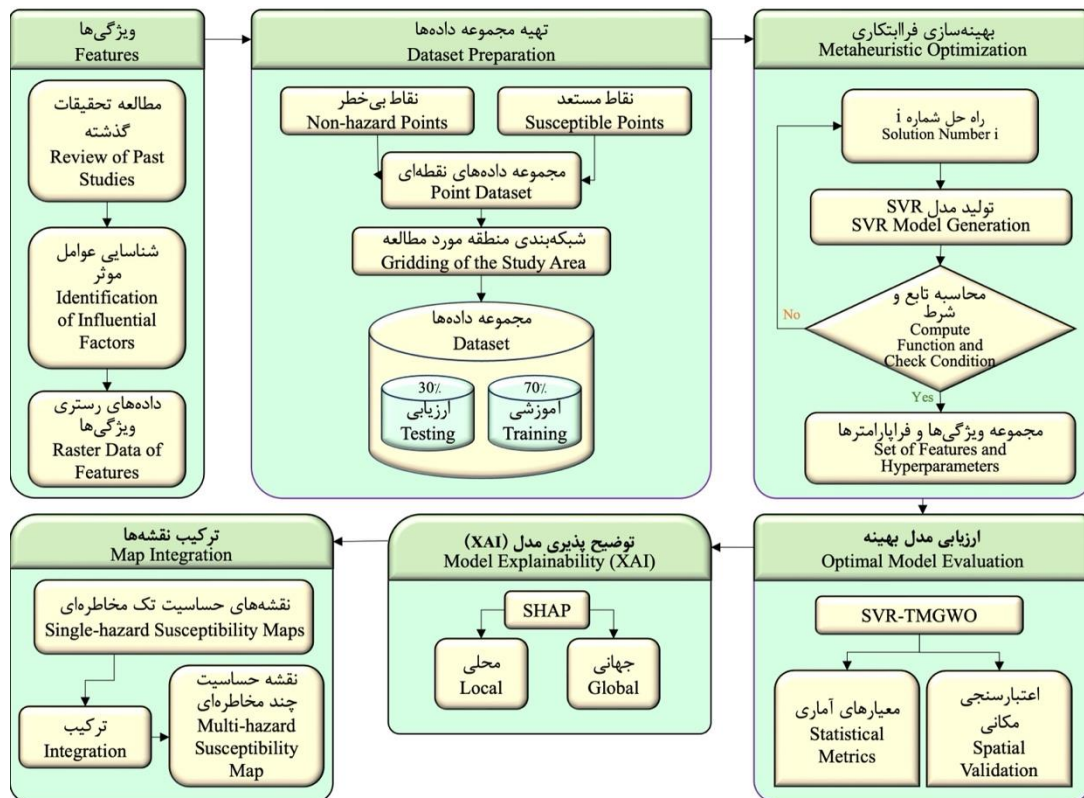
#### منطقه مورد مطالعه

استان‌های شمالی ایران (شکل ۲) شامل گلستان، مازندران و گیلان به دلیل شرایط اقلیمی مرطوب، شیب‌های تند دامنه‌ای و تغییرات کاربری اراضی، از جمله مناطق مستعد بروز هم‌زمان مخاطراتی نظیر سیلاب، زمین‌لغزش و فرونشست زمین به شمار می‌روند. در استان گلستان، وجود حدود ۴۵۲ هزار هکتار جنگل که بخش قابل‌توجهی از آن (حدود ۲۰۰ هزار هکتار) در معرض تخریب و بهره‌برداری قرار دارد، نقش مهمی در تغییر پاسخ هیدرولوژیکی حوضه‌ها ایفا کرده است [۱۱]. مطالعات انجام‌شده در این استان نشان‌دهنده فراوانی بالای زمین‌لغزش است؛ به طوری که در حوضه آبخیز گالیکش ۲۴۹ و در منطقه شهرستان کلاله ۸۲ داده زمین‌لغزش با استفاده از داده‌های میدانی، تصاویر ماهواره‌ای و سوابق تاریخی شناسایی شده است [۱۲، ۱۳].

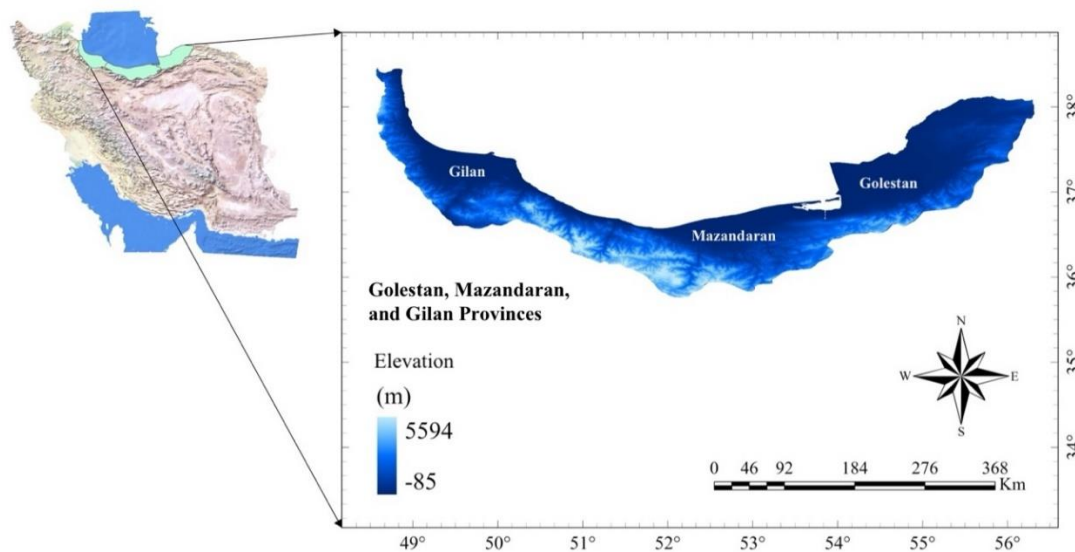
ROC برابر ۰/۸۳۴ برای سیل، ۰/۹۳۹ برای زمین‌لغزش و ۰/۹۴۳ برای آتش‌سوزی جنگلی را نشان داد و مشخص شد که تنها ۲/۶۷ درصد از منطقه به‌طور هم‌زمان در معرض هر سه مخاطره قرار دارد [۱]. افزون بر این، در پژوهشی دیگر رضوی ترمه و همکاران (۲۰۲۵) از الگوریتم‌های ژنتیک (Genetic Algorithm) و بهینه‌سازی ازدحام ذرات (Particle Swarm Optimization) برای ارتقای کارایی (Random RF) Forest بهره گرفته و دقت مدل‌ها را با استفاده از شاخص AUC-ROC ارزیابی کردند و نشان دادند که ترکیب الگوریتم‌های فراابتکاری با RF، عملکرد مدل پایه را برای هر چهار مخاطره (زمین‌لغزش، فرونشست، سیل و آتش‌سوزی) به‌طور قابل توجهی بهبود می‌بخشد [۵]. مطالعه دیگری انجام شده توسط یولاه و همکاران (۲۰۲۲) در منطقه شرق هندوکش پاکستان نیز از CNN (Convolutional Neural Network) برای برآورد حساسیت سیلاب ناگهانی، جریان‌های آریزه‌ای و زمین‌لغزش استفاده شده و نتایج این مدل با LR (Linear Regression) و KNN (K-Nearest Neighbors) مقایسه گردیده است؛ نتایجی که نشان می‌دهد CNN دقیق‌ترین مدل بوده است [۸].

تنظیم فراپارامترها در مدل‌های یادگیری ماشین نقش اساسی در دستیابی به عملکرد بهینه دارد. بنابراین تنظیم فراپارامتر برای جلوگیری از بیش‌برازش امری الزامی محسوب می‌شود [۱۰]. برای غلبه بر این محدودیت‌ها، از الگوریتم‌های بهینه‌سازی و فراابتکاری استفاده شده است؛ چنان‌که در پژوهش بالوگان و همکاران (۲۰۲۰)، مدل SVR (Support Vector Regression) با الگوریتم‌های (Bat BAT، GWO) و COA (Cuckoo Optimization Algorithm) ترکیب شده تا پارامترهای مدل به‌صورت دقیق تنظیم شوند و مشکل محدودیت بهینه‌سازی پارامترها رفع گردد [۹]. به‌طور مشابه، در پژوهش لیو و همکاران (۲۰۲۱)، ترکیب SVR با الگوریتم‌های FA و GWO به‌منظور بهبود دقت پیش‌بینی حساسیت زمین‌لغزش به کار رفته است [۶]. افزون بر این مسئله، انتخاب و اولویت‌بندی ویژگی‌های موثر نیز بخشی جدایی‌ناپذیر از فرآیند بهینه‌سازی مدل‌ها محسوب می‌شود و این مسئله در پژوهش‌های پیشین به دفعات نشان داده شده است که انتخاب ویژگی‌های مناسب می‌تواند نقش تعیین‌کننده‌ای در ارتقای کیفیت نقشه‌های حساسیت ایفا کند، به‌طور مثال مطالعه یوسفی و همکاران (۲۰۲۴) که از ترکیب الگوریتم Boruta با مدل XGBoost برای انتخاب بهینه ویژگی‌های مؤثر و افزایش دقت نقشه حساسیت زمین‌لغزش در استان کرمانشاه بهره گرفته‌اند [۴].

در این پژوهش، چارچوب مبتنی بر یادگیری ماشین برای تهیه نقشه حساسیت چندمخاطره‌ای استان‌های گلستان، مازندران و گیلان با تمرکز بر زمین‌لغزش، سیل و فرونشست زمین توسعه یافته است. در این فرایند، بهینه‌سازی هم‌زمان انتخاب ویژگی و تنظیم فراپارامترهای مدل SVR با استفاده از الگوریتم بهینه‌سازی (Two-Phase TMGWO Mutation GWO) انجام شد تا دقت پیش‌بینی افزایش یافته و از



شکل ۱: چارچوب پیشنهادی برای پژوهش  
Fig. 1: Suggested framework for this study



شکل ۲: منطقه مورد مطالعه: استان‌های گلستان، مازندران و گیلان  
Fig. 2: Study area: Golestan, Mazandaran, and Gilan provinces

در استان مازندران نیز شرایط ژئومورفولوژیکی و اقلیمی موجب افزایش حساسیت منطقه به زمین‌لغزش و سیلاب شده است. پژوهش‌های مختلف در این استان نشان داده‌اند که ترکیبی از عوامل توپوگرافی، کاربری اراضی و شرایط اقلیمی از جمله مهم‌ترین عوامل مؤثر در وقوع زمین‌لغزش گزارش شده‌اند [۱۷]. به‌عنوان نمونه، مدل‌سازی حساسیت زمین‌لغزش در حوضه آبخیز هراز در استان مازندران نشان داده است که بخش قابل توجهی از منطقه در کلاس‌های با خطر متوسط تا بسیار بالا

همچنین در جنگل‌های آرادباغ، ۷۸ نقطه زمین‌لغزش شناسایی شده و حدود ۱۳/۱۷۳۲ کیلومتر مربع از منطقه در کلاس‌های با خطر بالا تا بسیار بالا قرار دارد [۱۴]. علاوه بر این، پدیده فرونشست زمین نیز در این استان قابل توجه بوده و حدود ۵۰۰۰ کیلومتر مربع از اراضی تحت تأثیر آن قرار دارند، به‌طوری‌که نرخ فرونشست در برخی مناطق به بیش از ۱۲ سانتی‌متر در سال می‌رسد که عمدتاً ناشی از برداشت بی‌رویه آب‌های زیرزمینی برای مصارف کشاورزی است [۱۵، ۱۶].

انحنای نیم‌رخ با تأثیر بر شتاب جریان در امتداد شیب، نقش مهمی در فرایندهای فرسایش و رسوب‌گذاری و در نهایت پایداری دامنه ایفا می‌کند [۲۱].

علاوه بر عوامل طبیعی، پارامترهای محیطی و انسان‌ساخت نیز نقش قابل توجهی در بروز مخاطرات دارند. فاصله از جاده‌ها به دلیل ایجاد برش‌های مصنوعی در دامنه و تغییر در تعادل تنش، می‌تواند منجر به کاهش پایداری شیب و افزایش احتمال زمین‌لغزش شود [۱۲، ۱۷]. فاصله از گسل‌ها نیز به‌عنوان شاخصی از ضعف ساختاری، در کاهش مقاومت برشی مواد و افزایش حساسیت زمین‌لغزش مؤثر است [۱۲، ۱۷]. همچنین فاصله از رودخانه‌ها به‌واسطه فرسایش کناری و زیرشویی دامنه‌ها، یکی از عوامل کلیدی در ناپایداری شیب‌ها و تشدید سیلاب محسوب می‌شود [۱۲، ۲۲]. ویژگی‌های فیزیکی خاک نیز از جمله عوامل تعیین‌کننده در این زمینه هستند؛ به‌طوری‌که درصد شن با افزایش نفوذپذیری و کاهش چسبندگی، چگالی ظاهری با کنترل تراکم و زهکشی، و وجود قطعات درشت با تأثیر بر ساختار خاک، هر یک می‌توانند رفتار هیدرومکانیکی خاک را تغییر دهند [۱۲]. از سوی دیگر، خاک‌های سیلتی به‌دلیل حساسیت بالا به فرسایش و کاهش مقاومت در شرایط اشباع، و خاک‌های رسی به‌دلیل ویژگی‌های تورم و انقباض، از جمله عوامل مستعدکننده ناپایداری دامنه‌ها محسوب می‌شوند [۱۲، ۱۷]. تمامی ویژگی‌های استفاده شده در این پژوهش در شکل ۳ قابل مشاهده هستند.

#### داده‌های رخدادهای پیشین

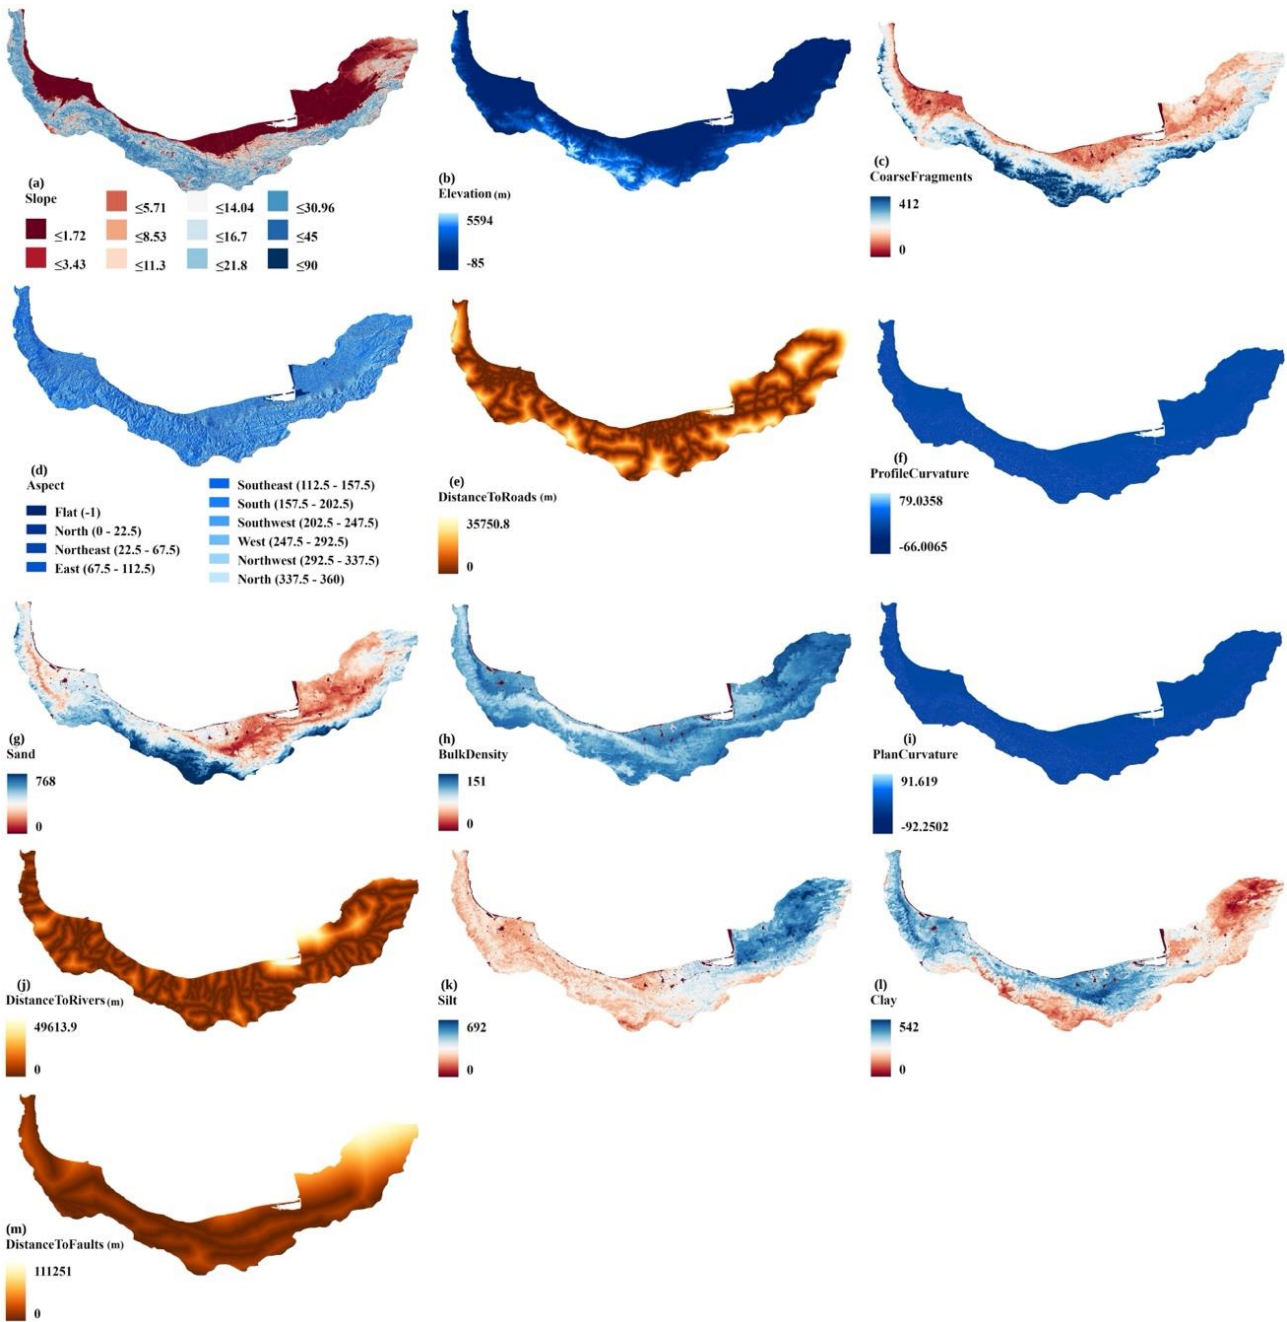
ایجاد یک پایگاه داده جامع از رخدادهای پیشین، زیربنای مدل‌سازی حساسیت با رویکرد یادگیری ماشین محسوب می‌شود؛ چرا که این داده‌ها نقشی کلیدی در تحلیل ارتباط میان پراکندگی فضایی مخاطرات و متغیرهای محیطی ایفا می‌کنند [۷، ۲۳]. در همین راستا، اطلاعات مکانی مربوط به سیلاب‌ها و زمین‌لغزش‌های رخ داده در یک دوره بیست‌ساله (۲۰۰۰ تا ۲۰۲۰) از طریق پایگاه‌های داده سازمان زمین‌شناسی و اکتشافات معدنی کشور (GSI) و همچنین سازمان منابع طبیعی و آبخیزداری ایران استخراج گردید. در بخش مخاطره فرونشست، از نتایج پژوهش حق‌شناس و متق (۲۰۲۴) استفاده شده است که با بهره‌گیری از تکنیک تداخل‌سنجی راداری (InSAR) و تحلیل بیش از ۶,۰۰۰ تصویر ماهواره‌ای سنتینل-۱، وضعیت فرونشست زمین را در بازه زمانی ۲۰۱۴ تا ۲۰۲۰ مانیتور کرده‌اند. این نقشه که با رزولوشن مکانی ۱۰۰ متر در سطح ملی تهیه شده، مبنای شناسایی نقاط فرونشست در این مطالعه قرار گرفت [۱۶]. به‌طور کلی، بانک اطلاعاتی این پژوهش در شکل ۴ به تصویر کشیده شده است.

قرار دارند [۱۷]. همچنین، بر اساس گزارش پایگاه داده رویدادهای اضطرابی (EM-DAT)، بیش از ۱۰ میلیون و ۲۰۰ هزار نفر از افراد ساکن استان مازندران تحت تأثیر سیلاب‌های بین سال‌های ۲۰۰۰ تا ۲۰۲۴ قرار گرفتند و مجموعاً بیش از ۴ میلیون و ۲۲۰ هزار دلار خسارت به این استان وارد شد.

استان گیلان نیز از جمله مناطق با پتانسیل بالای زمین‌لغزش محسوب می‌شود [۱۸]. مطالعات پیشین نشان داده‌اند که پارامترهایی نظیر شیب، لیتولوژی، کاربری اراضی و فاصله از گسل‌ها از مهم‌ترین عوامل کنترل‌کننده وقوع زمین‌لغزش در این مناطق هستند [۱۸]. علاوه بر این، بر اساس گزارش EM-DAT، بین سال‌های ۲۰۰۰ تا ۲۰۲۴، زندگی حدود ۱۰ میلیون و ۵۰۰ هزار نفر از ساکنین استان گیلان تحت تأثیر سیلاب قرار گرفته و حدود ۴ میلیون و ۳۰۰ هزار دلار خسارت به این استان وارد شد. مطالعه‌ای که در سال ۲۰۲۳ بر روی حوضه آبخیز فامناد در استان گیلان انجام شد، حدود ۳۴ درصد از کل مساحت این حوضه در طبقه با حساسیت بسیار زیاد نسبت به وقوع سیلاب قرار دارد و متغیرهای ارتفاع و فاصله از رودخانه به‌عنوان کلیدی‌ترین عوامل مؤثر در تحریک این مخاطره شناسایی شده‌اند [۱۹]. در مجموع، شواهد موجود از مطالعات مختلف نشان می‌دهد که سه استان شمالی کشور به‌طور هم‌زمان در معرض چندین مخاطره طبیعی قرار دارند و برهم‌کنش عوامل طبیعی و انسانی، شدت و فراوانی این رخدادهای را افزایش داده است؛ از این‌رو، این مناطق به‌عنوان نواحی اولویت‌دار برای مطالعات چندمخاطره‌ای و توسعه رویکردهای مدیریتی یکپارچه مطرح می‌شوند.

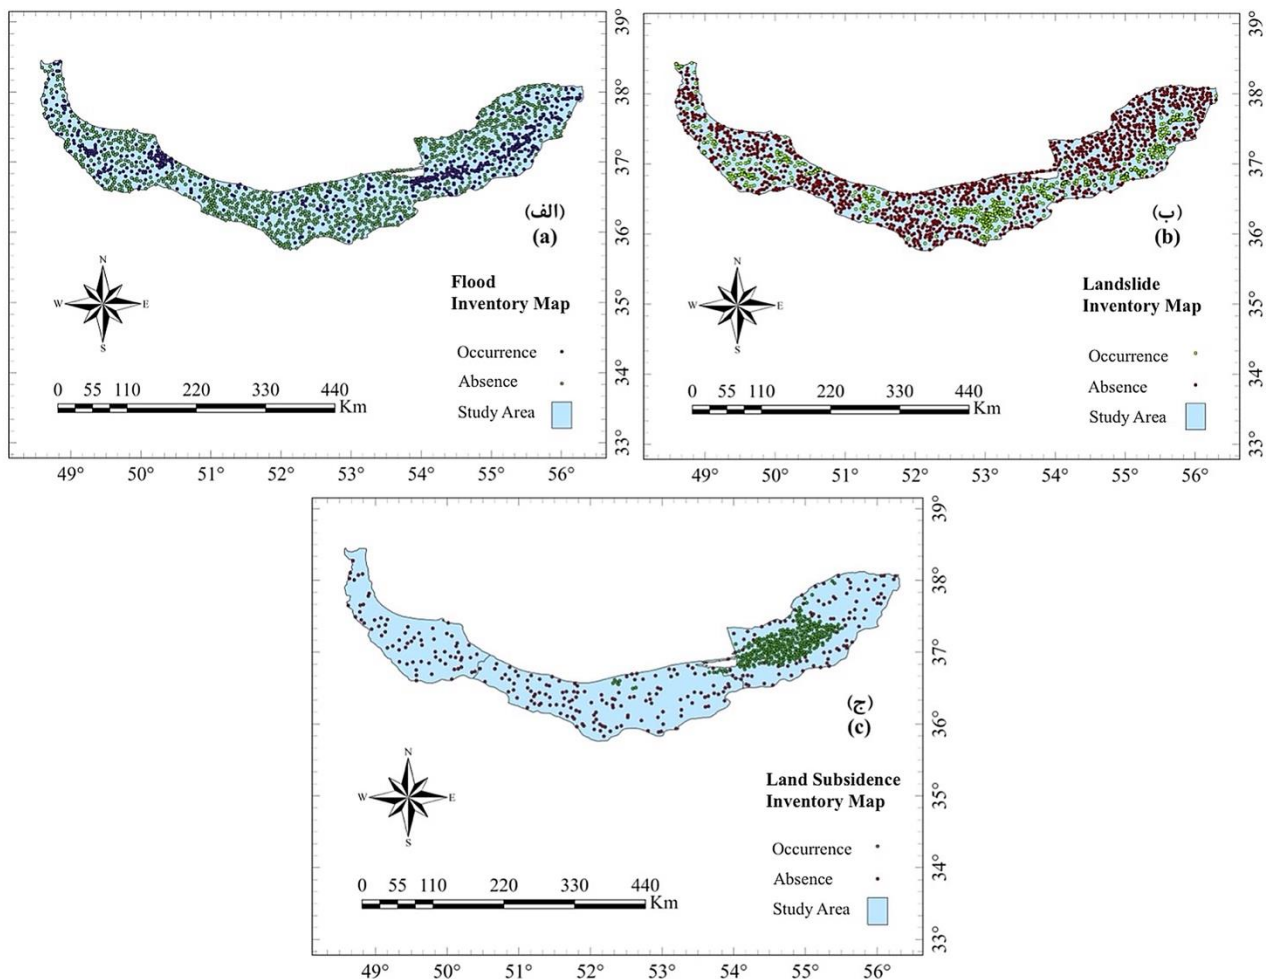
#### ویژگی‌های مورد بررسی

پارامترهای توپوگرافی از مهم‌ترین عوامل کنترل‌کننده در تحلیل حساسیت مخاطرات طبیعی به شمار می‌روند. ارتفاع به‌عنوان یک متغیر پایه، با تأثیرگذاری بر شرایط اقلیمی، الگوی بارش، پوشش گیاهی و میزان رواناب سطحی، نقش مهمی در پویایی دامنه‌ها ایفا می‌کند [۱۷]. شیب نیز به‌عنوان عامل اصلی در تعیین نیروی گرانشی وارد بر مواد دامنه‌ای، با افزایش مقدار خود موجب افزایش ناپایداری و احتمال وقوع زمین‌لغزش می‌شود و هم‌زمان بر سرعت و تمرکز رواناب در رخداد سیلاب تأثیرگذار است [۱۲، ۲۰]. جهت شیب از طریق کنترل میزان تابش دریافتی، رطوبت خاک و تراکم پوشش گیاهی، به‌صورت غیرمستقیم در پایداری دامنه‌ها نقش دارد [۱۲، ۱۷]. همچنین انحنای افقی با تعیین الگوی همگرایی و واگرایی جریان سطحی، در تمرکز یا پراکندگی رواناب و در نتیجه در اشباع خاک مؤثر است، به‌طوری‌که نواحی همگرا مستعد ناپایداری بیشتری هستند [۱۲، ۲۱]. در مقابل،



شکل ۳: نقشه ویژگی‌ها: الف) شیب، ب) ارتفاع، پ) قطعات درشت، ت) جهت شیب، ث) فاصله از جاده‌ها، ج) انحنای پروفیل، چ) محتوای ماسه، ح) چگالی ظاهری، خ) انحنای پلان، د) فاصله از رودخانه‌ها، ذ) محتوای لای، ر) محتوای رس، ز) فاصله از گسل‌ها

Fig. 3: Feature Maps: Feature Maps: a) Slope, b) Elevation, c) Coarse Fragments, d) Aspect, e) Distance from Roads, f) Profile Curvature, g) Sand content, h) Bulk Density, i) Plan Curvature, j) Distance from Rivers, k) Silt content, l) Clay content, m) Distance from Fault



شکل ۴: نقشه داده‌های تاریخی وقوع سیل، زمین‌لغزش، فرونشست زمین  
 Fig. 4: Historical Occurrence Data Maps: a) Flood, b) Landslide, c) Land Subsidence

منجر به دسته‌بندی داده‌ها بر اساس نزدیکی آن‌ها در فضای ویژگی می‌گردد و در نهایت تضمین می‌کند که توزیع داده‌ها در فضای ویژگی به‌طور متوازن در مجموعه‌های آموزش و آزمون حفظ شود، و در نتیجه از قرارگیری نمونه‌های مشابه در یک مجموعه و نمونه‌های متفاوت در مجموعه دیگر جلوگیری می‌شود.

#### مدل رگرسیون بردار پشتیبان

SVR یک روش یادگیری ماشین نظارت‌شده برای رگرسیون است که به‌عنوان توسعه‌ای از الگوریتم SVM برای مسائل پیش‌بینی پیوسته معرفی شد و عملکرد آن به‌طور عمده به انتخاب تابع هسته (kernel) وابسته است؛ به‌گونه‌ای که با ایجاد تعادل میان پیچیدگی مدل و خطای پیش‌بینی، به‌ویژه در مسائل غیرخطی، کارایی بالایی نشان می‌دهد و برای پیش‌بینی فضایی مناسب است [۶]. در مطالعات حساسیت زمین‌لغزش نیز SVR به‌طور گسترده به‌کار رفته و نشان داده شده است که با استفاده از الگوریتم‌های فراابتکاری مانند GWO، FA، BA و COA برای تنظیم فرامترها، دقت مدل به‌طور محسوسی افزایش می‌یابد؛ به‌عنوان مثال، مدل‌های هیبریدی مانند SVR-GWO و SVR-

#### توسعه و پیاده‌سازی نمونه‌برداری مکانی نقاط عدم رخداد

در این مطالعه جهت تولید نقاط عدم رخداد، ابتدا بافری ۲۰۰۰ متری اطراف نقاط رخداد با استفاده از نرم‌افزار ArcGIS Pro ترسیم شد. از این بافر جهت ایجاد فاصله‌ای قابل قبول بین نقاط رخداد موجود و محدوده تولید نقاط عدم رخداد استفاده شد. در ادامه، در منطقه مورد مطالعه و خارج از این بافر ۲۰۰۰ متری، نقاط عدم رخداد به صورت رندوم (همچون مطالعه ارابامری و همکاران (۲۰۲۰) [۱۲]) و با نسبتی برابر با نقاط رخداد تولید شدند تا توازن نقاط رخداد و عدم رخداد رعایت شده و مدل دچار سوگیری نشود [۶].

#### تقسیم‌بندی موضوعی داده‌ها

برای تقسیم‌بندی داده‌ها به گروه‌های آموزش و آزمون، از روش خوشه‌بندی K-Means استفاده شد؛ بدین صورت که ابتدا آنالیز Silhouette بر روی داده‌ها اجرا شد تا مقدار بهینه K بر اساس هر مجموعه داده، تشخیص داده شود. در ادامه، درون هر یک از خوشه‌ها، تقسیم‌بندی آموزش (۷۰٪) و آزمون (۳۰٪) انجام گرفت، مشابه با مطالعات پیشین همچون پژوهش لیو و همکاران (۲۰۲۱) [۶]. این امر

نرخ مثبت واقعی (حساسیت) و نرخ مثبت کاذب (ویژگی) کمی‌سازی می‌کند. مقدار AUC-ROC که بین ۰/۵ تا ۱ متغیر است، معیاری مستقل از آستانه برای سنجش قدرت تشخیص مدل فراهم می‌آورد، به طوری که مقادیر نزدیک به یک نشان‌دهنده انطباق عالی مدل با داده‌های مشاهداتی و قابلیت اطمینان بالای نقشه حساسیت تولید شده است [۱۲، ۳۰، ۳۱].

علاوه بر ارزیابی طبقه‌بندی، دقت عددی و میزان خطای پیش‌بینی مدل‌ها با استفاده از ریشه میانگین مربعات خطا (RMSE) مورد واکاوی قرار گرفت. این شاخص با محاسبه تفاوت میان مقادیر احتمالی پیش‌بینی شده و مقادیر واقعی در نقاط نمونه‌برداری، حساسیت بالایی نسبت به خطاهای بزرگ نشان می‌دهد و معیار مستقیمی از واریانس خطا فراهم می‌کند [۳۲]. هم‌زمان، برای تعیین میزان انطباق مدل با داده‌های آموزش و تست، از ضریب تعیین ( $R^2$ ) و ضریب تعیین تعدیل‌شده ( $R^2_{Adj}$ ) استفاده گردید. شاخص  $R^2$  نسبت واریانس تبیین شده توسط متغیرهای مستقل را نشان می‌دهد، در حالی که  $R^2_{Adj}$  با در نظر گرفتن تعداد پارامترهای ورودی، از برآورد بیش از حد دقت در مدل‌های پیچیده جلوگیری کرده و ارزیابی واقع‌بینانه‌تری از قدرت تعمیم‌دهی مدل ارائه می‌دهد [۳۳، ۳۴].

#### توضیح‌پذیری مدل

به منظور عبور از ماهیت مبهم و «جعبه‌سیاه» مدل‌های یادگیری ماشین، در این پژوهش از رویکرد مقادیر شپلی (SHAP) استفاده شد که بر پایه نظریه بازی‌های مشارکتی بنا شده است. این روش با ارائه دو سطح از تحلیل، شفافیت مدل را تضمین می‌کند: در مقیاس جهانی، اهمیت و سهم کلی هر یک از ویژگی‌های محیطی (مانند شیب، کاربری اراضی یا بارش) بر کل خروجی مدل مشخص می‌شود تا مشخص گردد کدام عوامل پیش‌ران اصلی وقوع مخاطرات در منطقه هستند. در مقابل، توضیح‌پذیری محلی بر تحلیل نقاط یا پیکسل‌های خاص متمرکز است و نشان می‌دهد که در یک نقطه معین، هر متغیر چگونه و با چه شدتی احتمال وقوع مخاطره را افزایش یا کاهش داده است. این ترکیب از تحلیل‌های کلان و خرد، نه تنها دقت پیش‌بینی مدل را اعتباربخشی می‌کند، بلکه بینش‌های ارزشمندی را برای مدیران بحران جهت اتخاذ تصمیمات مبتنی بر شواهد فراهم می‌آورد [۳۷-۳۵].

#### نتایج و خروجی‌ها

به منظور ارزیابی کارایی مدل‌های مورد استفاده در تهیه نقشه حساسیت چندمخاطره‌ای، عملکرد دو مدل SVR و SVR-TMGWO برای سه مخاطره سیلاب، زمین‌لغزش و فرونشست زمین در دو مرحله آموزش و آزمون مورد بررسی قرار گرفت. ارزیابی مدل‌ها بر اساس شاخص‌های آماری شامل ضریب تعیین ( $R^2$ )، ضریب تعیین تعدیل‌شده ( $R^2_{Adj}$ )، جذر میانگین مربعات خطا (RMSE) و سطح زیر منحنی (AUC-ROC) انجام شد. نتایج حاصل نشان داد که هر دو مدل توانایی قابل قبولی در

FA نسبت به SVR ساده عملکرد بهتری در پیش‌بینی مکانی زمین‌لغزش داشته‌اند و این موضوع نشان می‌دهد که SVR، به‌ویژه در ترکیب با بهینه‌سازهای فراابتکاری، گزینه‌ای مناسب برای مدل‌سازی مخاطرات طبیعی است [۶، ۹]. همچنین در پژوهش‌های مرتبط تأکید شده که تنظیم فرآیندها برای جلوگیری از بیش‌برازش و دستیابی به مدل بهینه، در کاربست‌های مکانی SVR ضروری است [۱۰].

عملکرد بهینه SVR با هسته تابع پایه شعاعی (RBF)، به‌طور مستقیم به تنظیم دقیق سه فرآیند کلیدی بستگی دارد: پارامتر جریمه (C) که تعادل میان میزان خطای آموزش و پیچیدگی مدل را کنترل می‌کند؛ پارامتر اپسیلون ( $\epsilon$ ) که عرض لوله حساسیت‌ناپذیر را تعیین کرده و بر تعداد بردارهای پشتیبان و صلبیت مدل تأثیر می‌گذارد؛ و پارامتر گاما ( $\gamma$ ) که گستره اثرگذاری هر نقطه آموزشی را مشخص کرده و نقش تعیین‌کننده‌ای در تعریف ساختار غیرخطی و جلوگیری از بیش‌برازش در فضای ویژگی ایفا می‌کند [۲۴، ۲۵]. مطالعات نشان می‌دهند که بهینه‌سازی هم‌زمان این سه مؤلفه از طریق الگوریتم‌های فراابتکاری، باعث بهبود کارایی مدل‌های یادگیری ماشین در پهنه‌بندی می‌شود [۲۶، ۲۷].

#### الگوریتم گرگ خاکستری

GWO یک الگوریتم فراابتکاری الهام‌گرفته از طبیعت است که با تقلید از سلسله‌مراتب اجتماعی و مکانیزم شکار گرگ‌های خاکستری طراحی شده و به‌عنوان روشی کارآمد برای جستجوی فضای پاسخ و یافتن راه‌حل‌های بهینه در مسائل پیچیده معرفی شده است [۲۸]. در مطالعات مرتبط با مدل‌سازی حساسیت زمین‌لغزش، GWO به‌طور مؤثر برای تنظیم فرآیندهای مدل‌های یادگیری ماشین، به‌ویژه SVR، به‌کار گرفته شده و نشان داده است که می‌تواند با بهبود فرآیند بهینه‌سازی، دقت پیش‌بینی مکانی را افزایش دهد [۹]. افزون بر این، پژوهش‌های جدیدتر نسخه‌های توسعه‌یافته‌ای از این الگوریتم را پیشنهاد کرده‌اند؛ از جمله TMGWO که ترکیبی از GWO با جهش دو مرحله‌ای (Two-Phase Mutation) است و با هدف تقویت توان اکتشاف، بهبود بهره‌برداری و افزایش دقت در انتخاب ویژگی طراحی شده است [۲۹]. بر این اساس، GWO و نسخه‌های بهبودیافته آن، به‌ویژه TMGWO، ابزارهای مؤثری برای جستجوی بهینه در فضای پارامتر و ویژگی هستند و در ارتقای عملکرد مدل‌های پیش‌بینی مخاطرات طبیعی نقش مهمی ایفا می‌کنند.

#### ارزیابی عملکرد و صحت‌سنجی نقشه‌های حساسیت

در این مطالعه، به‌منظور ارزیابی دقیق توانمندی مدل‌های یادگیری ماشین در پیش‌بینی پهنه‌های حساسیت، از شاخص سطح زیر منحنی مشخصه عملکرد گیرنده (AUC-ROC) استفاده شد. این معیار به‌عنوان یکی از معتبرترین شاخص‌ها در مدل‌سازی‌های مکانی، توانایی مدل را در تفکیک صحیح مناطق حساس از غیرحساس بر اساس توازن میان

مقدار AUC-ROC برابر با ۰/۹۸۳۸، RMSE معادل ۰/۲۰۸۲ و  $R^2$  برابر با ۰/۸۲۶۷ بود که بیانگر همبستگی قوی میان داده‌های پیش‌بینی شده و مشاهدات واقعی است. در مرحله آزمون نیز این مدل عملکرد مناسبی داشته و مقادیر AUC-ROC، RMSE و  $R^2$  به ترتیب برابر با ۰/۹۵۱۹، ۰/۲۶۶۲ و ۰/۷۱۶۱ گزارش شد. مدل SVR-TMGWO اگرچه در مرحله آموزش مقادیری بسیار نزدیک به مدل پایه ( $AUC=0/9812$ )،  $RMSE=0/2128$  و  $R^2=0/8189$  ارائه داد، اما در مرحله آزمون عملکرد بهتری از خود نشان داد؛ به گونه‌ای که مقدار AUC-ROC به ۰/۹۶۴۲،  $R^2$  به ۰/۷۴۶۵ افزایش و RMSE به ۰/۲۵۱۷ کاهش یافت. این نتایج بیانگر کارایی الگوریتم ترکیبی در افزایش پایداری مدل و کاهش خطای پیش‌بینی در نواحی مستعد فرونشست است.

بررسی مقادیر فرآپارامترهای بهینه‌شده مدل SVR-TMGWO نیز نشان داد که برای هر مخاطره، ترکیب متفاوتی از پارامترها انتخاب شده است (جدول ۳-۲). مقدار پارامتر C برای مخاطره فرونشست زمین برابر با ۱/۰۹۸۶، برای سیلاب برابر با ۰/۵۲۹۰ و برای زمین‌لغزش برابر با ۰/۱۹۱۲ به دست آمد. همچنین مقدار پارامتر گاما در مدل سیلاب برابر با ۱ گزارش شد، در حالی که برای زمین‌لغزش و فرونشست زمین به ترتیب مقادیر ۰/۳۱۸۴ و ۰/۲۸۲۹ ثبت گردید. مقدار پارامتر E در هر سه مخاطره برابر با ۰/۱ تنظیم شد که نشان‌دهنده پایداری ساختار مدل در کنترل خطای مجاز است. تفاوت در مقادیر فرآپارامترها بیانگر تفاوت ماهیت داده‌ها و الگوهای مکانی حاکم بر هر یک از مخاطرات مورد بررسی است.

بررسی مقادیر فرآپارامترهای بهینه‌شده مدل SVR-TMGWO نیز نشان داد که برای هر مخاطره، ترکیب متفاوتی از پارامترها و ویژگی‌ها انتخاب شده‌اند (جدول ۲ و ۳). مقدار پارامتر C برای مخاطره سیلاب برابر با ۰/۳۰۵۶، برای زمین‌لغزش برابر با ۴۴/۸۸۳۰ و برای فرونشست زمین برابر با ۰/۴ به دست آمد. اختلاف چشمگیر مقدار C در مخاطره زمین‌لغزش نسبت به دو مخاطره دیگر نشان‌دهنده تفاوت ماهیت داده‌ها و نیاز این مخاطره به جریمه بزرگ‌تر برای خطاهای آموزش است. مقدار پارامتر گاما (۷) در مدل سیلاب برابر با ۱ گزارش شد، در حالی که برای زمین‌لغزش و فرونشست زمین به ترتیب مقادیر ۰/۵۳۷ و ۰/۱۹۸۹ به دست آمد. مقدار پارامتر اپسیلون (E) برای مخاطرات سیلاب و فرونشست زمین برابر با ۰/۱ و برای زمین‌لغزش برابر با ۰/۰۹۲۸ تنظیم شد. تفاوت در مقادیر فرآپارامترها بیانگر تفاوت ماهیت داده‌ها و الگوهای مکانی حاکم بر هر یک از مخاطرات مورد بررسی است.

شناسایی نواحی مستعد مخاطرات طبیعی داشته‌اند، با این حال میزان دقت و پایداری مدل‌ها در مخاطرات مختلف متفاوت بوده است (جدول ۱).

بررسی نتایج مربوط به مخاطره سیلاب نشان داد که مدل پایه SVR در مرحله آموزش دارای مقدار AUC-ROC برابر با ۰/۹۰۰۴ و RMSE معادل ۰/۳۵۹۰ بوده است، در حالی که در مرحله آزمون، مقادیر AUC-ROC و RMSE به ترتیب برابر با ۰/۸۲۶۱ و ۰/۴۲۱۹ به دست آمد. همچنین مقدار  $R^2$  در مرحله آموزش برابر با ۰/۴۸۴۲ و در مرحله آزمون برابر با ۰/۲۸۶۹ ثبت گردید که نشان‌دهنده کاهش نسبتاً قابل توجه توان تعمیم مدل در داده‌های آزمون است. در مقابل، مدل SVR-TMGWO عملکرد بهتری را در هر دو مرحله آموزش و آزمون نشان داد؛ به طوری که مقدار AUC-ROC در مرحله آموزش به ۰/۹۳۳۹ و RMSE به ۰/۳۰۶۴ رسید و مقدار  $R^2$  نیز به ۰/۶۲۴۴ افزایش یافت که نسبت به مدل پایه بهبود محسوسی را نمایش می‌دهد. در مرحله آزمون نیز مدل بهینه‌سازی شده با مقدار AUC-ROC برابر با ۰/۸۴۰۴، RMSE معادل ۰/۴۰۸۳ و  $R^2$  برابر با ۰/۳۳۲۳ همچنان بر مدل پایه برتری داشت. این نتایج بیانگر تأثیر مثبت الگوریتم TMGWO در بهینه‌سازی فرآپارامترهای SVR و بهبود قابلیت تفکیک مناطق حساس به سیلاب است.

در ارتباط با مخاطره زمین‌لغزش، هر دو مدل عملکرد مطلوبی از خود نشان دادند. مدل SVR در مرحله آموزش دارای مقدار AUC-ROC برابر با ۰/۹۵۹۰، RMSE معادل ۰/۲۷۹۴ و  $R^2$  برابر با ۰/۶۸۷۵ بود. در مرحله آزمون نیز مقدار AUC-ROC برابر با ۰/۹۲۸۲، RMSE برابر با ۰/۳۲۹۰ و  $R^2$  برابر با ۰/۵۶۵۴ ثبت گردید که بیانگر توان قابل قبول این مدل در تبیین پراکنش فضایی زمین‌لغزش‌ها است. در مدل SVR-TMGWO، اگرچه مقادیر شاخص‌های مرحله آموزش اندکی پایین‌تر از مدل پایه و به ترتیب برابر با  $AUC-ROC=0/9479$ ،  $RMSE=0/2945$  و  $R^2=0/6528$  به دست آمد، اما در مرحله آزمون مقدار AUC-ROC به ۰/۹۳۲۹،  $R^2$  به ۰/۵۸۹۴ افزایش و RMSE به ۰/۳۱۹۸ کاهش یافت. این موضوع نشان می‌دهد که مدل بهینه‌سازی شده در مرحله آزمون از پایداری بیشتری برخوردار بوده و توانسته است الگوی مکانی زمین‌لغزش‌ها را با دقت بالاتری بازنمایی کند؛ به عبارت دیگر، الگوریتم TMGWO با کنترل بیش‌برازش، توان تعمیم‌پذیری مدل را افزایش داده است.

نتایج مربوط به فرونشست زمین نشان‌دهنده بالاترین سطح دقت در میان سه مخاطره مورد مطالعه بود. مدل SVR در مرحله آموزش دارای

جدول ۱: نتایج شاخص‌های ارزیابی  
Table 1: Evaluation metrics' results

Hazard	Model	Data	Adj. $R^2$	$R^2$	RMSE	AUC-ROC
Flood	SVR	Train	0.4793	0.4842	0.359	0.9004
		Test	0.2711	0.2869	0.4219	0.8261
	SVR-TMGWO	Train	0.6209	0.6244	0.3064	0.9339
		Test	0.3175	0.3323	0.4083	0.8404

Hazard	Model	Data	Adj. R <sup>2</sup>	R <sup>2</sup>	RMSE	AUC-ROC
Landslide	SVR	Train	0.6849	0.6875	0.2794	0.959
		Test	0.5571	0.5654	0.329	0.9282
	SVR-TMGWO	Train	0.65	0.6528	0.2945	0.9479
		Test	0.5816	0.5894	0.3198	0.9329
Land Subsidence	SVR	Train	0.8211	0.8267	0.2082	0.9838
		Test	0.694	0.7161	0.2663	0.9519
	SVR-TMGWO	Train	0.8131	0.8119	0.2128	0.9812
		Test	0.7267	0.7465	0.2517	0.9642

جدول ۲: مقادیر فرآپارامترها برای هر مخاطره پس از بهینه‌سازی با SVR-TMGWO

Table 2: Hyperparameter values for each hazard after optimization with SVR-TMGWO

Hyperparameters	Flood	Landslide	Land Subsidence
C	0.3056	44.883	0.4
Epsilon (ε)	0.1	0.0928	0.1
Gamma (γ)	1	0.0537	0.1989

جدول ۳: ویژگی‌های انتخاب شده

Table 3: Selected features

Features	Hazard	Flood	Landslide	Land Subsidence
Elevation		✓	✓	✓
Slope			✓	
Slope Aspect				
Distance to Rivers		✓	✓	
Distance to Roads		✓	✓	✓
Distance to Faults		✓	✓	✓
Plan Curvature				
Profile Curvature				
Bulk Density				
Coarse Fragments		✓		✓
Clay Content		✓	✓	✓
Sand Content				✓
Silt Content		✓	✓	✓

به‌طور کلی، نتایج حاصل از اعتبارسنجی مدل‌ها نشان داد که استفاده از الگوریتم TMGWO در فرآیند بهینه‌سازی مدل SVR موجب بهبود دقت پیش‌بینی، افزایش توان تفکیک مکانی و کاهش میزان خطا در اغلب سناریوهای مورد بررسی به‌ویژه در مرحله آزمون شده است. در میان مخاطرات سه‌گانه، مدل‌های مورد استفاده در شناسایی فرونشست زمین بالاترین دقت را داشته‌اند، در حالی که مخاطره سیلاب نسبت به سایر مخاطرات دارای پیچیدگی و عدم قطعیت بیشتری بوده و مقادیر AUC-ROC و R<sup>2</sup> پایین‌تری به‌ویژه در مرحله آزمون به دست آمده است. الگوی کلی نتایج حاکی از آن است که مدل ترکیبی SVR-TMGWO توانایی مناسبی در تهیه نقشه‌های حساسیت چندمخاطره‌ای در مقیاس منطقه‌ای داشته و می‌تواند به‌عنوان رویکردی کارآمد در مطالعات مدیریت و برنامه‌ریزی مخاطرات طبیعی مورد استفاده قرار گیرد. پس از ارزیابی کمی مدل‌ها، نقشه‌های حساسیت سه مخاطره سیلاب، زمین‌لغزش و فرونشست زمین با استفاده از مدل بهینه‌سازی‌شده SVR

به‌طور کلی، نتایج حاصل از اعتبارسنجی مدل‌ها نشان داد که استفاده از الگوریتم TMGWO در فرآیند بهینه‌سازی مدل SVR موجب بهبود دقت پیش‌بینی، افزایش توان تفکیک مکانی و کاهش میزان خطا در اغلب سناریوهای مورد بررسی به‌ویژه در مرحله آزمون شده است. در میان مخاطرات سه‌گانه، مدل‌های مورد استفاده در شناسایی فرونشست زمین بالاترین دقت را داشته‌اند، در حالی که مخاطره سیلاب نسبت به سایر مخاطرات دارای پیچیدگی و عدم قطعیت بیشتری بوده و مقادیر AUC-ROC و R<sup>2</sup> پایین‌تری به‌ویژه در مرحله آزمون به دست آمده است. الگوی کلی نتایج حاکی از آن است که مدل ترکیبی SVR-TMGWO توانایی مناسبی در تهیه نقشه‌های حساسیت چندمخاطره‌ای در مقیاس منطقه‌ای داشته و می‌تواند به‌عنوان رویکردی کارآمد در مطالعات مدیریت و برنامه‌ریزی مخاطرات طبیعی مورد استفاده قرار گیرد. پس از ارزیابی کمی مدل‌ها، نقشه‌های حساسیت سه مخاطره سیلاب، زمین‌لغزش و فرونشست زمین با استفاده از مدل بهینه‌سازی‌شده SVR

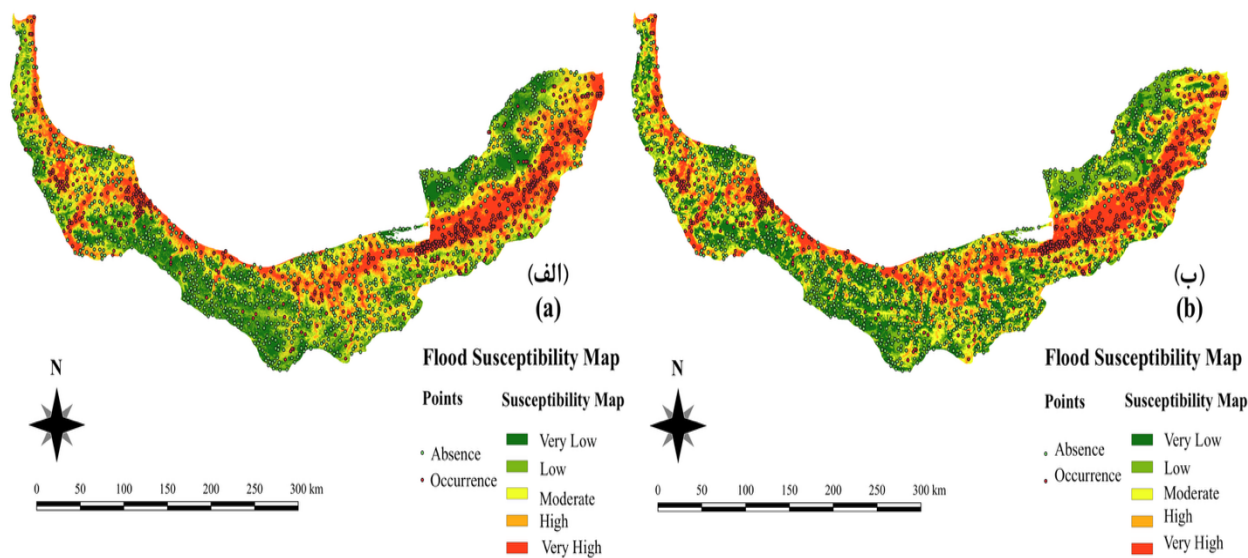
که ارتفاع از سطح دریا مهم‌ترین متغیر اثرگذار بر خروجی مدل بوده است؛ به‌گونه‌ای که مقادیر پایین این متغیر (نقاط آبی) با مقادیر مثبت SHAP همراه بوده و افزایش احتمال وقوع سیل را در پی داشته‌اند، در حالی که مقادیر بالای ارتفاع (نقاط قرمز/صورتی) عمدتاً سهمی منفی در پیش‌بینی ایفا کرده‌اند. این الگو با ماهیت فیزیکی سیل که عمدتاً در نواحی کم‌ارتفاع و دشت‌های هموار رخ می‌دهد، کاملاً سازگار است. متغیرهای فاصله از جاده‌ها، فاصله از گسل‌ها و درصد رس به ترتیب در رتبه‌های دوم تا چهارم اهمیت قرار گرفتند. در مورد فاصله از رودخانه‌ها که در رتبه پنجم قرار دارد، الگوی روشنی مشاهده شد؛ به‌طوری‌که فواصل کوتاه‌تر (نقاط آبی) با مقادیر مثبت SHAP و فواصل بیشتر (نقاط قرمز) با مقادیر منفی همبسته بودند که این یافته با اصول هیدرولوژیکی شناخته‌شده در پهنه‌بندی سیل کاملاً مطابقت دارد. درصد سیلت در پایین‌ترین رتبه اهمیت قرار گرفت، اما الگوی منظمی از خود نشان داد؛ به‌طوری‌که مقادیر بالای سیلت با سهم مثبت در پیش‌بینی سیل همراه بوده است که این رفتار با حضور خاک‌های سیلتی-رسی در دشت‌های آبرفتی و سیلابی منطقه قابل تبیین است. در مقابل، رس رفتاری معکوس از خود نشان داد؛ به‌گونه‌ای که مقادیر بالای آن سهم منفی در پیش‌بینی داشته است، که احتمالاً بازتاب‌دهنده تمرکز نسبی خاک‌های رسی در پهنه‌های مرتفع‌تر و دامنه‌های منطقه و دور از کریدورهای اصلی سیلابی است.

TMGWO تهیه گردید (شکل‌های ۵، ۸ و ۱۱). در این نقشه‌ها، پهنه‌های حساسیت با استفاده از روش چندک (Quantile) به پنج طبقه «بسیار پایین»، «پایین»، «متوسط»، «بالا» و «بسیار بالا» تقسیم‌بندی شده‌اند. تحلیل الگوی مکانی هر یک از این نقشه‌ها و تطابق آن با نقاط رخداد ثبت شده، ابزار مفیدی برای ارزیابی کیفی مدل و درک ماهیت فضایی هر مخاطره فراهم می‌سازد.


### سیل

نقشه حساسیت سیل (شکل ۵) نشان می‌دهد که پهنه‌های با حساسیت بسیار بالا و بالا (طبقات قرمز و نارنجی) عمدتاً در نواحی کم‌ارتفاع مرکزی منطقه و در امتداد دشت‌های ساحلی و باریکه‌های رودخانه‌ای متمرکز شده‌اند. این الگو در بخش‌های شمال‌غربی و مرکزی به صورت یک نوار پیوسته دیده می‌شود، در حالی که در نواحی کوهستانی جنوبی و حاشیه‌ای، طبقات بسیار پایین و پایین (سبز) غالب هستند. تطابق بصری بین نقاط رخداد سیل ثبت شده (نقاط قرمز) و طبقات با حساسیت بالا، بیانگر توانایی مناسب مدل در شناسایی مناطق مستعد است؛ به‌طوری‌که بخش قابل توجهی از نقاط رخداد در طبقات «بالا» و «بسیار بالا» قرار گرفته‌اند.

به‌منظور تحلیل سهم هر یک از متغیرهای ورودی در پیش‌بینی حساسیت سیل و درک رفتار کلی مدل SVR-TMGWO، از روش SHAP در مقیاس جهانی استفاده شد (شکل ۶). نتایج به‌دست آمده نشان داد



شکل ۵: نقشه حساسیت سیل با مدل الف) SVR و ب) SVR-TMGWO  
Fig. 5: Flood susceptibility map with a) SVR, and b) SVR-TMGWO



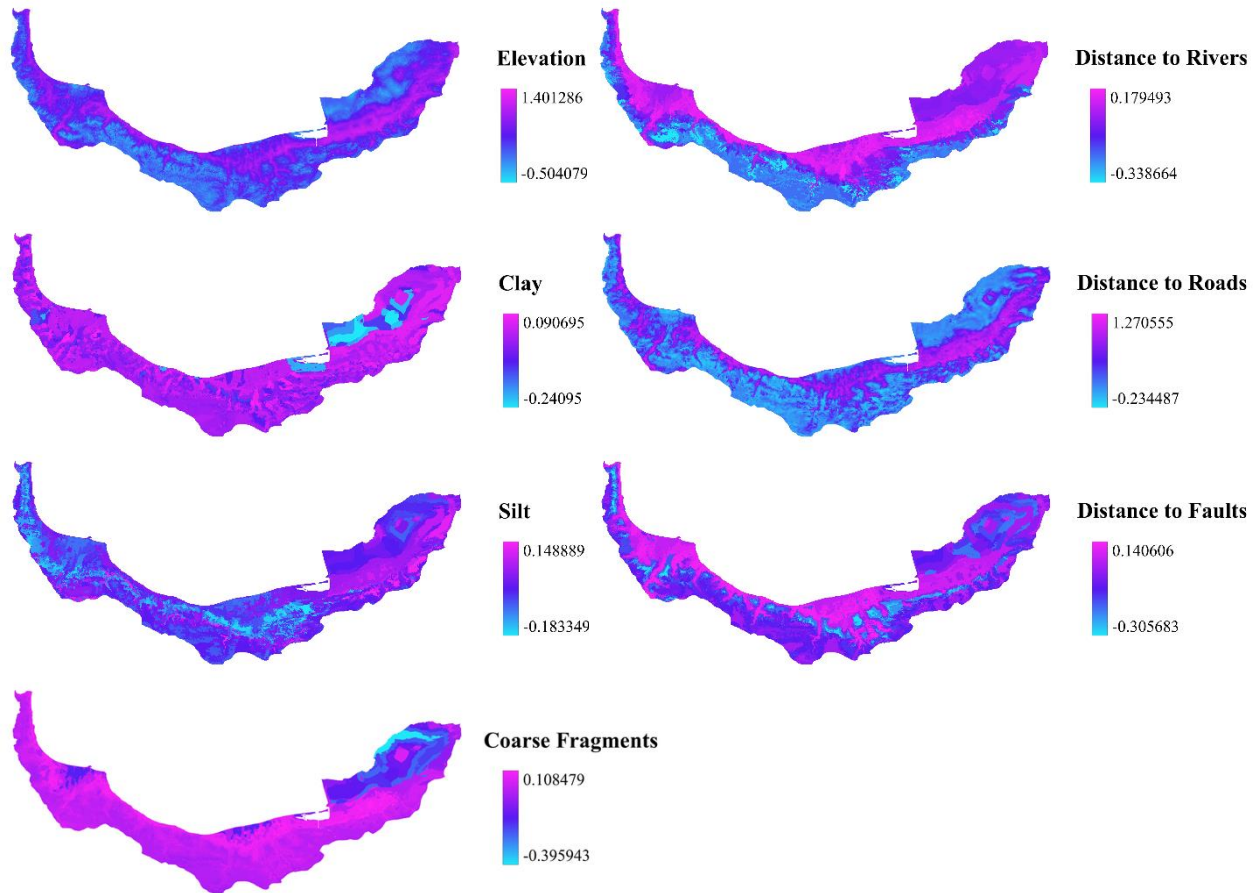
شکل ۶: نقشه توضیح‌پذیری جهانی SHAP برای هر ویژگی مخاطره سیل  
Fig. 6: Global SHAP Explainability Maps for each feature of the Flood Hazard

دشت‌های هموار و کریدورهای سیلابی، رس در پهنه‌های دامنه‌ای و میان‌ارتفاع، و قطعات درشت در نواحی کوهستانی الگوهای متمایزی ارائه می‌کنند. این تحلیل مکانی نه تنها قابلیت تفسیرپذیری مدل SVR-TMGWO را افزایش می‌دهد، بلکه امکان شناسایی عوامل غالب در هر بخش از منطقه را فراهم می‌سازد و ابزار ارزشمندی برای مدیریت ریسک محلی و برنامه‌ریزی کاهش اثرات سیل در اختیار قرار می‌دهد.

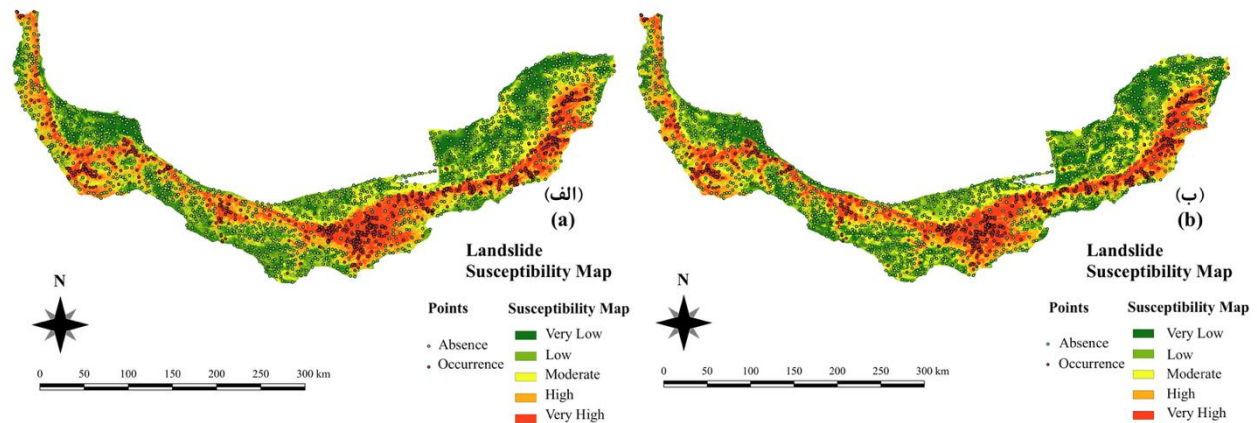
#### زمین‌لغزش

نقشه حساسیت زمین‌لغزش (شکل ۸) الگوی فضایی متفاوتی را نسبت به سیل به نمایش می‌گذارد. در این نقشه، نواحی با حساسیت بالا و بسیار بالا عمدتاً در پهنه‌های میان‌ارتفاع و کمربندهای دامنه‌ای واقع در بخش‌های مرکزی و جنوب-مرکزی منطقه متمرکز شده‌اند؛ یعنی همان نواحی انتقالی بین کوهستان و دشت که از نظر شیب، لیتولوژی و رطوبت خاک دارای شرایط مستعد ناپایداری دامنه هستند. برخلاف مخاطره سیل، دشت‌های کم‌ارتفاع در نقشه زمین‌لغزش عمدتاً در طبقات حساسیت پایین قرار گرفته‌اند. تجمع چشمگیر نقاط رخداد در طبقات قرمز و نارنجی، به‌ویژه در بخش‌های جنوبی و مرکزی نقشه، نشان‌دهنده تطابق بالا میان خروجی مدل و واقعیت مشاهداتی است و عملکرد مناسب مدل را که پیش‌تر با مقدار AUC-ROC در مرحله آزمون تأیید شده بود، به صورت بصری نیز پشتیبانی می‌کند.

به‌منظور بررسی توزیع فضایی سهم هر یک از متغیرها در پیش‌بینی حساسیت سیل، تحلیل SHAP در مقیاس محلی نیز انجام و نتایج آن به صورت نقشه‌های مجزا برای هفت متغیر اصلی نمایش داده شد (شکل ۷). در این نقشه‌ها، رنگ‌های صورتی و ارغوانی روشن نشان‌دهنده سهم مثبت متغیر در افزایش احتمال وقوع سیل و رنگ‌های آبی روشن بیانگر سهم منفی (کاهنده) آن در هر پیکسل هستند. نقشه SHAP متغیر ارتفاع گسترده‌ترین دامنه تأثیر را نشان داد؛ به طوری که نوار باریک ساحلی در شمال منطقه و دشت‌های هموار شرقی که از ارتفاع پایینی برخوردارند، بیشترین سهم مثبت را در پیش‌بینی سیل ایفا کرده‌اند، در حالی که نواحی کوهستانی جنوبی و حاشیه‌ای، سهمی منفی (آبی) داشته‌اند. نقشه فاصله از دومین دامنه تأثیر گسترده را نشان می‌دهد و بازتاب‌دهنده اهمیت دسترسی، فعالیت‌های انسانی و سطوح نفوذناپذیر در شکل‌گیری پهنه‌های پرخطر سیل است. نقشه فاصله از رودخانه‌ها نیز الگویی متمرکز در امتداد کریدورهای رودخانه‌ای ارائه می‌دهد و سهم مثبت قابل توجهی را در نواحی نزدیک به آبراهه‌ها نشان می‌دهد، که با اصول کلاسیک هیدرولوژی سیل سازگار است. نقشه فاصله از گسل‌ها بیانگر ارتباط غیرمستقیم این متغیر با شرایط توپوگرافی و زمین‌شناختی منطقه است که خود بر الگوی وقوع سیل اثرگذار است. در میان متغیرهای خاک‌شناختی، نقشه‌های رس، سیلت و قطعات درشت توزیع فضایی ناممکنی از سهم خود نشان می‌دهند؛ به گونه‌ای که سیلت در



شکل ۷: نقشه توضیح‌پذیری محلی SHAP برای هر ویژگی مخاطره سیل  
 Fig. 7: Local SHAP explainability map for each feature of flood hazard



شکل ۸: نقشه حساسیت زمین‌لغزش با مدل الف (SVR) و ب (SVR-TMGWO)  
 Fig. 8: Landslide susceptibility map with a) SVR, and b) SVR-TMGWO


بعدی قرار داشتند. در مورد ارتفاع، الگوی پیچیده‌تری نسبت به مدل سیل مشاهده شد؛ به‌گونه‌ای که مقادیر بسیار بالای ارتفاع عمدتاً سهم منفی در پیش‌بینی داشتند، در حالی که مقادیر پایین تا متوسط سهم مثبتی نشان دادند. این الگو با ماهیت فیزیکی زمین‌لغزش سازگار است، چرا که بیشترین وقوع آن در پهنه‌های میان‌ارتفاع و دامنه‌ای رخ می‌دهد، نه در ارتفاعات بسیار زیاد که عمدتاً متشکل از سنگ بستر مقاوم و

برخلاف مدل سیل که در آن متغیرهای توپوگرافی-هیدرولوژیکی نقش غالب داشتند، در مدل زمین‌لغزش ترکیب متفاوتی از متغیرهای توپوگرافی، خاک‌شناختی و زمین‌شناختی به‌عنوان عوامل کلیدی شناسایی شدند (شکل ۹). ارتفاع از سطح دریا، درصد لای و شیب به‌ترتیب در سه رتبه نخست اهمیت قرار گرفتند، در حالی که فاصله از گسل‌ها، درصد رس، فاصله از جاده‌ها و فاصله از رودخانه‌ها در رتبه‌های

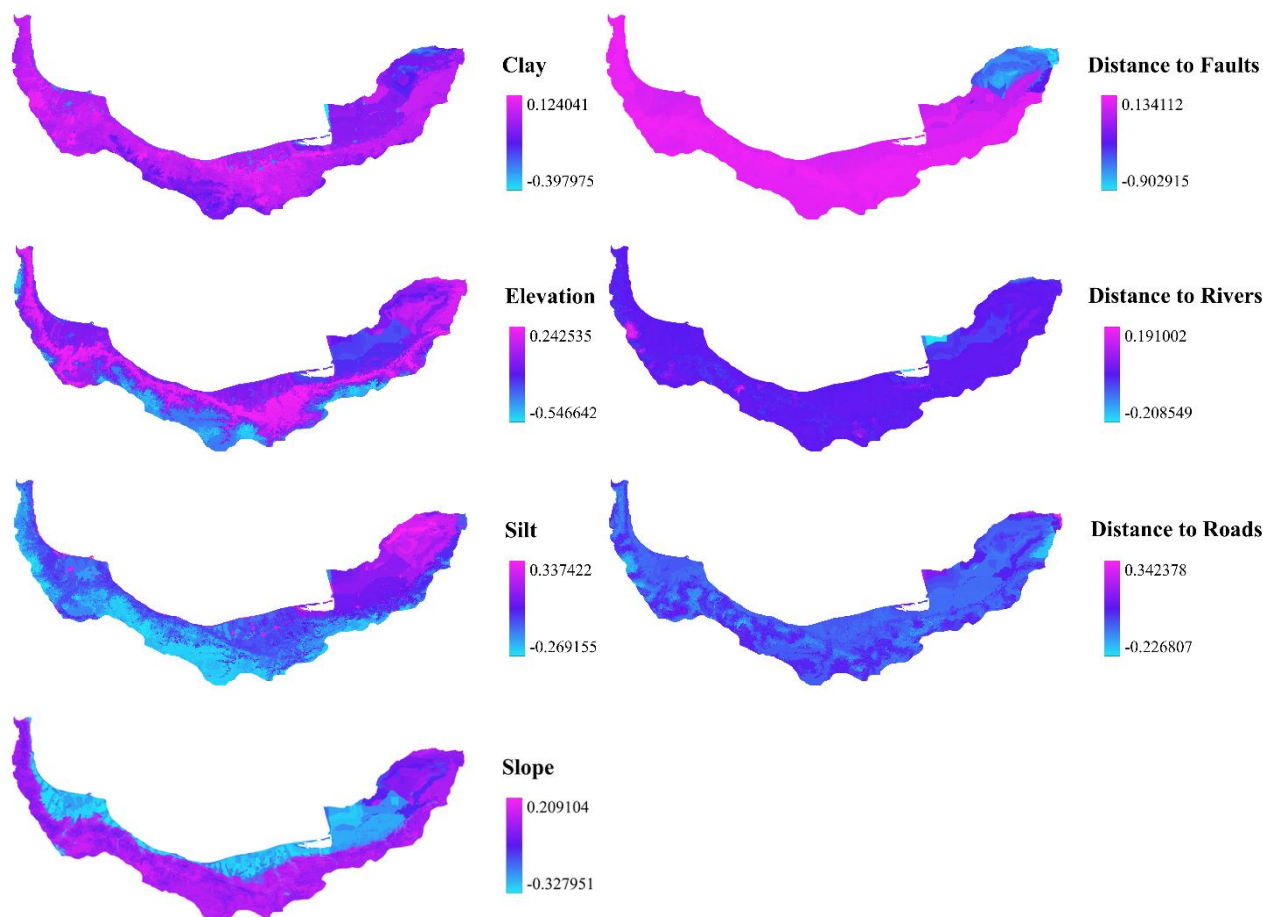
منفی شدید در پیش‌بینی، یعنی کاهش احتمال زمین‌لغزش با افزایش فاصله، قابل تشخیص است، در حالی که نواحی نزدیک به گسل، رنگ ارغوانی روشن (سهام مثبت) نشان می‌دهند. نقشه SHAP متغیر ارتفاع بازتاب‌دهنده تأثیر غیرخطی ارتفاع در بخش‌های مختلف منطقه است؛ پهنه‌های میان‌ارتفاع و دامنه‌ای در بخش‌های مرکزی و جنوبی سهم مثبت، و قله‌های بسیار مرتفع شمال‌شرقی سهم منفی نشان داده‌اند. نقشه شیب نیز با تمرکز رنگ‌های صورتی-ارغوانی در پهنه‌های پرشیب جنوبی و مرکزی، نقش شناخته‌شده شیب در ناپایداری دامنه‌ای را به خوبی منعکس می‌سازد. در میان متغیرهای خاک‌شناختی، نقشه لای بیش‌ترین سهم مثبت را در میان متغیرهای خاک نشان داد و الگوی فضایی واضحی از تمرکز سهم مثبت در پهنه‌های دامنه‌ای ارائه می‌دهد. نقشه رس توزیع ناهمگنی از سهم خود نشان می‌دهد که بازتاب‌دهنده تنوع خاک‌شناختی منطقه است. نقشه فاصله از جاده‌ها سهم مثبت مشخصی در نواحی شرقی منطقه نشان می‌دهد که می‌تواند به نقش ساخت‌وساز جاده‌ها در ناپایداری دامنه‌ها از طریق برش‌های ناصحیح، تخلیه نامناسب آب‌های سطحی و تخریب پوشش گیاهی نسبت داده شود. نقشه فاصله از رودخانه‌ها با دامنه نسبتاً محدود، کمترین تنوع فضایی را در میان متغیرها نشان می‌دهد، که با رتبه پایین اهمیت این متغیر در تحلیل جهانی همخوانی دارد. به‌طور کلی، الگوی مکانی SHAP در مدل زمین‌لغزش بیانگر تعامل پیچیده متغیرهای توپوگرافی، زمین‌شناختی و خاک‌شناختی در شکل‌گیری پهنه‌های حساس است و توان مدل SVR-TMGWO را در ارائه پیش‌بینی‌های مکان‌مند و قابل تفسیر تأیید می‌کند.

پوشش خاکی محدود هستند. درصد لای رفتاری بسیار روشن نشان داد؛ مقادیر بالای آن به‌طور مشخص با سهم مثبت SHAP همراه بودند، که با حساسیت بالای خاک‌های دارای لای نسبت به ناپایداری دامنه‌ای در شرایط رطوبتی کاملاً مطابقت دارد. متغیر شیب نیز همان‌طور که از اصول فیزیکی زمین‌لغزش انتظار می‌رود، الگوی واضحی از خود نشان داد: مقادیر بالای شیب با سهم مثبت و مقادیر پایین آن با سهم منفی همبسته بودند. در مورد فاصله از گسل‌ها، گسترده‌ترین دامنه تأثیر منفی در میان همه متغیرها مشاهده شد؛ به‌طوری‌که مقادیر بالای این متغیر تا حدود  $-0/8$  در محور SHAP کشیده شده‌اند، که نشان می‌دهد فاصله بیشتر از گسل‌ها به‌شدت احتمال وقوع زمین‌لغزش را کاهش می‌دهد و در مقابل، نزدیکی به گسل‌ها از عوامل قطعی حساسیت بالا محسوب می‌شود. این یافته با نقش شناخته‌شده گسل‌ها در تضعیف توده‌های سنگی، شکستگی‌سازی و افزایش پتانسیل ناپایداری دامنه کاملاً سازگار است. درصد رس نیز سهم نسبتاً مثبتی در پیش‌بینی نشان داد که با کاهش نفوذپذیری خاک، افزایش فشار آب منفذی و کاهش مقاومت برشی توده خاک در شرایط اشباع قابل توضیح است. در نهایت، فاصله از رودخانه‌ها در پایین‌ترین رتبه اهمیت قرار گرفت که با ماهیت زمین‌لغزش به‌عنوان پدیده‌ای دامنه‌ای-زمین‌شناختی (در مقایسه با سیل که پدیده‌ای آبراه‌ای است) همسوست.

در میان متغیرهای بررسی‌شده در نقشه‌های SHAP محلی (شکل ۱۰)، فاصله از گسل‌ها گسترده‌ترین دامنه تأثیر را از خود نشان داد، که بیانگر نقش بسیار مهم این متغیر در مقیاس محلی است. این الگو در نواحی نزدیک به گسل‌های اصلی منطقه به‌صورت پهنه‌های آبی روشن (سهم



شکل ۹: نقشه توضیح‌پذیری جهانی SHAP برای هر ویژگی مخاطره زمین‌لغزش  
 Fig. 9: Global SHAP Explainability Maps for each feature of the landslide hazard



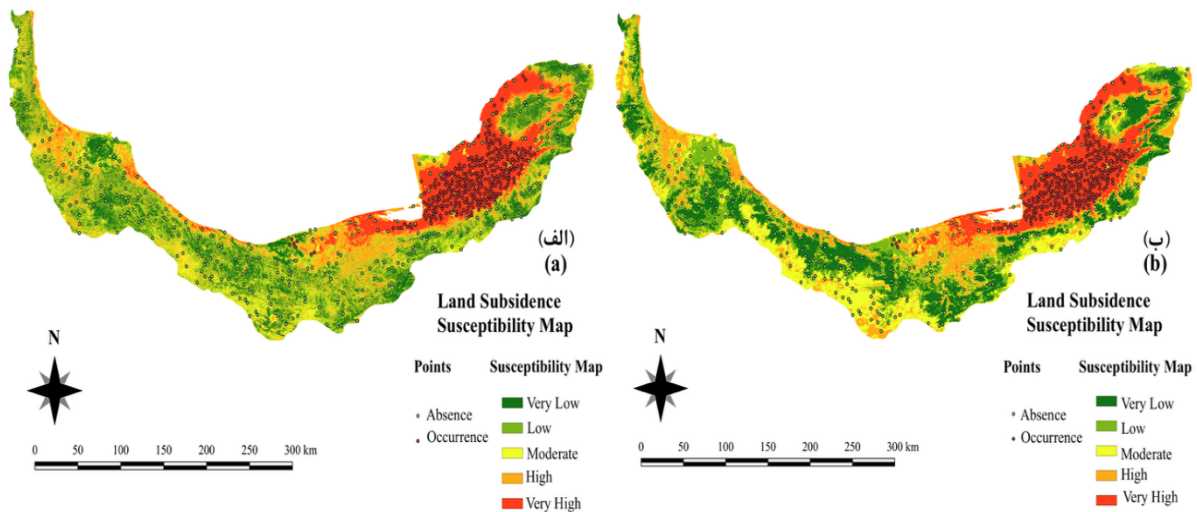
شکل ۱۰: نقشه توضیح‌پذیری محلی SHAP برای هر ویژگی مخاطره زمین‌لغزش  
 Fig. 10: Local SHAP explainability map for each feature of landslide hazard

#### فرونشست زمین


نقشه حساسیت فرونشست زمین (شکل ۱۱) بارزترین تمرکز فضایی را در میان سه مخاطره مورد مطالعه نشان می‌دهد؛ به‌گونه‌ای که یک پهنه گسترده و پیوسته با حساسیت بسیار بالا در بخش شرقی منطقه قابل تشخیص است. این پهنه به‌طور کامل با دشت‌های هموار و کم‌ارتفاع شرقی منطقه منطبق بوده و الگویی متراکم و یکپارچه دارد که با ماهیت تدریجی و گسترده فرونشست زمین سازگار است. در بخش غربی منطقه، طبقات متوسط و بالا (زرد و نارنجی) غالب هستند و تنها در نوارهای محدودی، حساسیت بسیار بالا مشاهده می‌شود. تجمع نقاط رخداد فرونشست در پهنه قرمز بخش شرقی، عملکرد دقیق مدل را تأیید می‌کند و با مقدار بالای AUC-ROC در مرحله آزمون همخوانی کامل دارد. این الگوی فضایی به‌خوبی با مکانیسم فیزیکی فرونشست در ایران مطابقت دارد، چرا که مطالعات متعددی نشان داده‌اند برداشت بی‌رویه آب زیرزمینی در دشت‌های کشاورزی، عامل اصلی فرونشست در مناطق هموار است. به‌عنوان نمونه، محمدی و همکاران (۲۰۱۹) در استان سمنان و رحمتی و همکاران (۲۰۱۹) در دشت همدان، الگویی مشابه از تمرکز فرونشست در پهنه‌های هموار با افت سطح آب زیرزمینی را گزارش کرده‌اند [۲۲، ۳۸]. همچنین، تعداد کمتر نقاط رخداد فرونشست

در مقایسه با دو مخاطره دیگر، با ماهیت کندتر و کم‌نمودتر این پدیده در مقایسه با سیل و زمین‌لغزش سازگار است.

نتایج به‌دست‌آمده برای توضیح‌پذیری جهانی (شکل ۱۲) نشان دادند که برخلاف مدل‌های سیل و زمین‌لغزش، در مدل فرونشست متغیرهای خاک‌شناختی نقش غالب در پیش‌بینی ایفا می‌کنند؛ به‌گونه‌ای که از هفت متغیر اصلی، چهار متغیر (لای، قطعات درشت، رس و ماسه) به ماهیت خاک مربوط هستند. این یافته از منظر فیزیکی کاملاً منطقی است، چرا که فرونشست زمین اساساً پدیده‌ای تابع قابلیت تراکم رسوبات تحت اثر کاهش فشار آب منفذی است. ارتفاع از سطح دریا با اختلاف قابل توجه به‌عنوان مهم‌ترین متغیر شناخته شد؛ به‌طوری‌که مقادیر بالای ارتفاع عمده‌تأ سهم منفی شدید در پیش‌بینی نشان دادند، در حالی که مقادیر پایین ارتفاع به‌صورت متراکم در ناحیه سهم مثبت قرار گرفته‌اند. این الگو با ماهیت پدیده فرونشست که عمدتاً در دشت‌های هموار و کم‌ارتفاع همراه با برداشت بی‌رویه آب زیرزمینی رخ می‌دهد، کاملاً سازگار است. درصد سیلت در رتبه دوم اهمیت قرار گرفت و الگوی بسیار روشنی نشان داد؛ مقادیر بالای لای به‌طور قابل ملاحظه‌ای با سهم مثبت SHAP همراه بودند، که با حساسیت بالای رسوبات سیلتی-آبرفتی نسبت به تراکم تحت اثر افت سطح آب زیرزمینی سازگار است.



شکل ۱۰: نقشه حساسیت فرونشست زمین با مدل الف (SVR) و ب (SVR-TMGWO)  
 Fig. 10: Land subsidence susceptibility map with a) SVR, and b) SVR-TMGWO



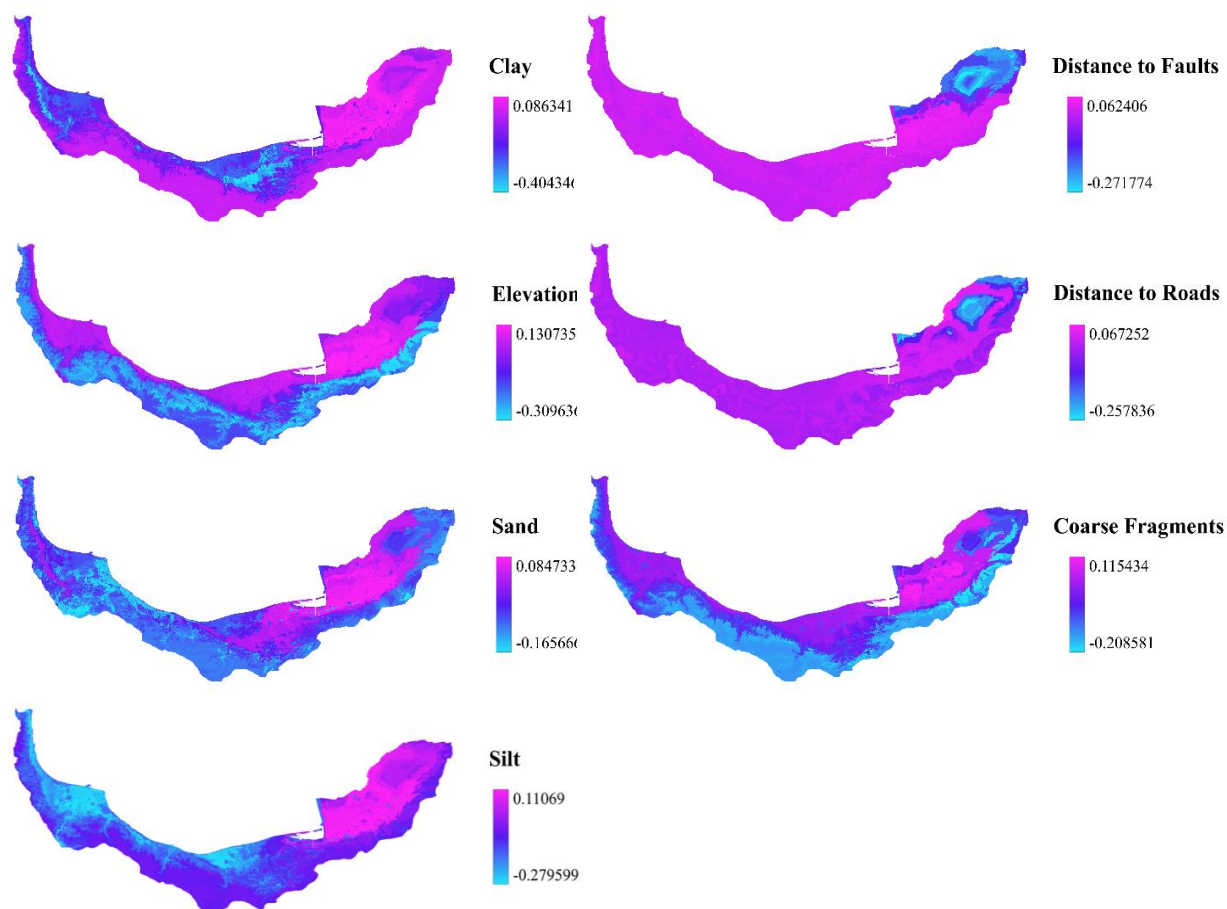
شکل ۱۲: نقشه توضیح‌پذیری جهانی SHAP برای هر ویژگی مخاطره فرونشست زمین  
 Fig. 12: Global SHAP Explainability Maps for each feature of the land subsidence hazard

نسبت داده شود، که احتمالاً در پهنه‌های دامنه‌ای و خارج از کانون‌های اصلی فرونشست متمرکز هستند. درصد ماسه نیز رفتار قابل انتظاری نشان داد؛ مقادیر بالای ماسه با سهم منفی همبسته بودند که با زهکشی بهتر و تراکم‌پذیری کمتر رسوبات ماسه‌ای سازگار است. متغیر فاصله از گسل‌ها نشان داد که فواصل کوتاه از گسل‌ها (نقاط قرمز در سهم منفی) با کاهش پیش‌بینی فرونشست همراه است، که می‌تواند بازتاب‌دهنده غلبه فرونشست در حوضه‌های آبرفتی مرکزی به‌جای پهنه‌های شکستگی‌دار باشد. در نهایت، فاصله از جاده‌ها در پایین‌ترین رتبه اهمیت

متغیر قطعات درشت رفتاری معکوس از خود نشان داد؛ به‌گونه‌ای که مقادیر پایین این متغیر با سهم مثبت همبسته بودند، که با این واقعیت سازگار است که رسوبات ریزدانه‌تر و فاقد شن و قطعات درشت، قابلیت تراکم بیشتری در شرایط افت سطح آب زیرزمینی دارند. در مورد رس، الگوی نسبتاً پیچیده‌ای مشاهده شد؛ به‌گونه‌ای که مقادیر بالای رس سهم منفی نسبتاً گسترده‌ای در پیش‌بینی ایفا کرده‌اند که در نگاه اول با ادبیات کلاسیک فرونشست متفاوت به‌نظر می‌رسد. این رفتار می‌تواند به الگوی توزیع فضایی خاص خاک‌های رسی در منطقه مورد مطالعه

ارائه می‌کنند؛ به گونه‌ای که نواحی با درصد قطعات درشت و ماسه پایین در دشت‌های شرقی، سهم مثبت در پیش‌بینی فرونشست داشته‌اند. این تطابق فضایی متقابل بین متغیرهای بافتی خاک، توان مدل-SVR-TMGWO را در شناسایی پهنه‌های با ترکیب رسوبی تراکم‌پذیر تأیید می‌کند. نقشه فاصله از گسل‌ها با دامنه نسبتاً محدود یکنواختی فضایی نسبی نشان می‌دهد و عمدتاً در پهنه شرقی منطقه سهم مثبت اندکی ارائه می‌کند، در حالی که نواحی نزدیک به گسل‌های اصلی در شمال شرقی منطقه، سهم منفی شدیدی نشان داده‌اند. نقشه فاصله از جاده‌ها نیز با دامنه الگوی فضایی مشابهی نمایان می‌سازد. به‌طور کلی، الگوهای SHAP محلی نشان می‌دهد که در مدل فرونشست، ترکیب متغیرهای ارتفاع پایین و رسوبات سیلتی-آبرفتی فاقد قطعات درشت و ماسه، شرایط ایده‌آلی برای پیش‌بینی فرونشست بالا فراهم می‌کنند. این یافته بازتاب‌دهنده تطابق نتایج مدل با واقعیت زمین‌شناختی و هیدروژئولوژیکی فرونشست در دشت‌های ایران است و توان توضیح‌پذیری مدل SVR-TMGWO را در شناسایی الگوهای علی فرونشست تأیید می‌نماید.

قرار گرفت که اثر نسبتاً محدود متغیر انسانی-ساختاری در مقایسه با عوامل ذاتی خاک و توپوگرافی را نشان می‌دهد. طبق نقشه‌های توضیح‌پذیری محلی (شکل ۱۳)، رس با گسترده‌ترین دامنه منفی قابل توجه‌ترین تنوع فضایی را در میان متغیرها نشان داد؛ به گونه‌ای که بخش‌های جنوبی و حاشیه‌ای منطقه که از پوشش رسی بیشتری برخوردارند، با رنگ آبی روشن (سهم منفی شدید در پیش‌بینی) متمایز شده‌اند. این الگو نشان می‌دهد که مدل به‌درستی موقعیت‌های با ترکیب رسی واقع در پهنه‌های نامستعد فرونشست را شناسایی کرده است. نقشه ارتفاع بازتاب‌دهنده وابستگی قوی فرونشست به توپوگرافی هموار است؛ به طوری که دشت‌های شرقی و نوار ساحلی شمالی منطقه که از ارتفاع پایینی برخوردارند، با رنگ ارغوانی روشن (سهم مثبت) نمایان شده‌اند، در حالی که ارتفاعات جنوبی سهم منفی نشان می‌دهند. این الگو به خوبی با نقشه حساسیت فرونشست (شکل ۱۱) که تمرکز پهنه‌های بسیار بالا را در دشت‌های شرقی نشان می‌دهد، همخوانی دارد. نقشه لای سهم مثبت قابل توجهی در پهنه‌های دشتی شرقی نشان می‌دهد، در حالی که بخش‌های ساحلی شمالی و دامنه‌ای جنوبی سهم منفی دارند. نقشه‌های قطعات درشت و ماسه الگویی مکمل با سیلت

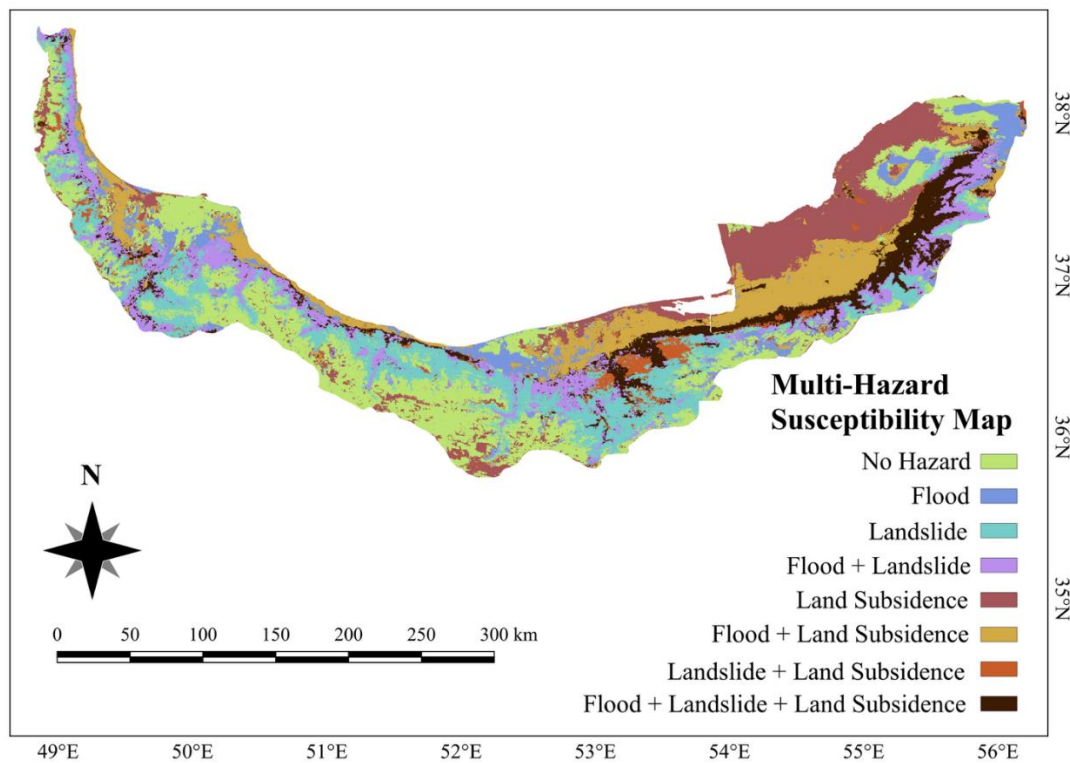


شکل ۱۳: نقشه توضیح‌پذیری محلی SHAP برای هر ویژگی مخاطره فرونشست زمین  
Fig. 13: Local SHAP explainability map for each feature of land subsidence hazard

## چندمخاطره‌ای

پهنه‌ها، وقوع یک مخاطره می‌تواند زمینه‌ساز تشدید یا تسهیل سایر مخاطرات شود. این رویکرد یکپارچه برای پهنه‌بندی چندمخاطره‌ای، با مطالعات مشابه در مناطق مختلف ایران همخوانی دارد. به‌عنوان نمونه، پورقاسمی و همکاران (۲۰۲۰) در استان فارس و چهار حوضه آبخیز راهبردی آن، با استفاده از الگوریتم‌های Boruta و RF، نقشه‌های حساسیت چندمخاطره‌ای سه خطر طبیعی شامل سیل، زمین‌لغزش و آتش‌سوزی جنگلی را تهیه کردند و نتایج آن مطالعه نشان داد که تنها ۲/۶۷ درصد از مساحت به‌طور همزمان در معرض هر سه مخاطره است؛ یافته‌ای که با الگوی به‌دست‌آمده در پژوهش حاضر مبنی بر تمرکز پهنه‌های با همپوشانی سه‌گانه در نواحی محدود و خاص منطقه همخوانی دارد [۱]. همچنین یوسفی و همکاران (۲۰۲۰) در جنوب غربی ایران (استان چهارمحال و بختیاری)، با استفاده از مدل‌های یادگیری ماشین SVM، BRT، GLM و FDA، حساسیت پنج مخاطره طبیعی شامل بهمن، زمین‌لغزش، آتش‌سوزی جنگلی، فرونشست زمین و سیل را مدل‌سازی کردند و نشان دادند که SVM دقیق‌ترین مدل برای سه مخاطره زمین‌لغزش، فرونشست و سیل بوده است؛ این یافته با انتخاب مدل پایه SVR در پژوهش حاضر و عملکرد قوی آن در تفکیک هر سه مخاطره مورد بررسی هم‌راستا است [۲]. در مجموع، نقشه حساسیت چندمخاطره‌ای حاصل از مدل SVR-TMGWO، ابزاری کارآمد برای شناسایی پهنه‌های در معرض ریسک تجمعی و اولویت‌بندی مناطق مستعد در مدیریت یکپارچه مخاطرات طبیعی فراهم می‌سازد.

پس از تهیه نقشه‌های حساسیت برای هر یک از سه مخاطره به‌صورت جداگانه، با ترکیب این نقشه‌ها و طبقه‌بندی مجدد نواحی بر اساس همپوشانی مخاطرات، نقشه نهایی حساسیت چندمخاطره‌ای منطقه تهیه شد (شکل ۱۴). این نقشه پهنه‌های مطالعاتی را به هشت طبقه تقسیم می‌کند: نواحی بدون مخاطره، سه طبقه برای حساسیت به یک مخاطره به‌تنهایی (سیل، زمین‌لغزش، یا فرونشست زمین)، سه طبقه برای همپوشانی دوگانه میان مخاطرات، و یک طبقه نهایی برای نواحی متأثر از هر سه مخاطره به‌طور همزمان. تحلیل بصری این نقشه نشان می‌دهد که بخش قابل توجهی از منطقه مورد مطالعه، تنها در معرض یک مخاطره قرار دارد و الگوی فضایی این مخاطره‌های منفرد با ماهیت فیزیکی و عوامل کنترل‌کننده هر یک مطابقت دارد؛ به‌گونه‌ای که فرونشست زمین در دشت‌های هموار شرقی، زمین‌لغزش در پهنه‌های میان‌ارتفاع و دامنه‌ای، و سیل در نوارهای ساحلی و کریدورهای رودخانه‌ای متمرکز شده‌اند. در عین حال، پهنه‌های با همپوشانی دوگانه و سه‌گانه که نمایانگر بحرانی‌ترین مناطق از منظر مدیریت ریسک هستند، عمدتاً در نواحی انتقالی میان کوهستان و دشت و در حاشیه پهنه‌های پرفرونشست شکل گرفته‌اند. این مناطق دوگانه و به‌ویژه پهنه‌های سه‌گانه که در آن‌ها سیل، زمین‌لغزش و فرونشست به‌طور همزمان رخ می‌دهند، نیازمند توجه ویژه در برنامه‌ریزی کاربری اراضی، توسعه زیرساخت و سیاست‌های کاهش ریسک هستند؛ چرا که در این



شکل ۱۴: نقشه حساسیت چندمخاطره‌ای استان‌های گلستان، گیلان و مازندران

Fig. 14: Multi-hazard susceptibility map of Golestan, Gilan and Mazandaran provinces

## نتایج و بحث

نتایج دقت نسبتاً پایین مدل برای پیش‌بینی سیلاب ( $R^2=0/3323$ ) در مرحله آزمون) را می‌توان به ماهیت پویا و وابسته به رویداد سیلاب نسبت داد؛ موضوعی که در مطالعه خاتاخو و همکاران (۲۰۲۱) در دره کاتماندو نپال نیز به‌عنوان منبع عدم قطعیت در پهنه‌بندی سیلاب مطرح شده است [۱۷].

## تحلیل پهنه‌بندی حساسیت زمین‌لغزش

نقشه حساسیت زمین‌لغزش، تمرکز پهنه‌های پرخطر را در نواحی میان‌ارتفاع و کمربندهای دامنه‌ای نشان داد، که با شواهد میدانی موجود از مطالعات پورقاسمی و همکاران (۲۰۱۲) در حوضه آبخیز هراز استان مازندران و پورقاسمی و همکاران (۲۰۱۳) در استان گلستان همخوانی دارد [۱۳، ۱۷]. در تحلیل SHAP، ارتفاع، درصد سیلت و شیب به‌ترتیب در سه رتبه نخست اهمیت قرار گرفتند. این یافته با مطالعه بهرامی و همکاران (۲۰۲۱) در استان گیلان که شیب و فاصله از گسل‌ها را به‌عنوان عوامل غالب معرفی کرده‌اند، هم‌راستاست [۱۸].

دامنه گسترده تأثیر منفی متغیر فاصله از گسل‌ها در نمودار SHAP (تا حدود  $-0/8$ ) با مطالعه مستوری و همکاران (۲۰۲۲) در جنگل‌های آرادباغ گلستان که گسل را از عوامل کلیدی شناسایی کرده‌اند [۱۴]، و نتایج اربامری و همکاران (۲۰۲۰) در حوضه گالیکش، تأیید می‌شود [۱۲]. از منظر فیزیکی، نزدیکی به گسل‌ها از طریق شکستگی‌سازی، کاهش مقاومت برشی و افزایش فعالیت لرزه‌ای، حساسیت زمین‌لغزش را افزایش می‌دهد. رفتار غیرخطی متغیر ارتفاع (سهام منفی برای ارتفاعات بسیار بالا و سهم مثبت برای میان‌ارتفاع‌ها) نیز نشان‌دهنده توان مدل SVR-TMGWO در شناسایی روابط غیرخطی پیچیده است؛ توانمندی که از مزایای کلیدی روش‌های یادگیری ماشین در مقایسه با روش‌های آماری سنتی محسوب می‌شود [۳].

## تحلیل پهنه‌بندی حساسیت فرونشست زمین

بالاترین دقت در میان سه مخاطره به مدل فرونشست زمین تعلق داشت ( $AUC-ROC=0/9642$  در مرحله آزمون)، که این موضوع را می‌توان به ماهیت پیوسته و منظم پدیده فرونشست در مقایسه با رخداد‌های ناگهانی سیل و زمین‌لغزش نسبت داد. تمرکز پهنه‌های پرخطر در دشت‌های هموار شرقی منطقه با مطالعه حق‌شانس حقیقی و همکاران (۲۰۲۴) که با تکنیک تداخل‌سنجی راداری (InSAR) نرخ‌های فرونشست بالا را در دشت‌های گلستان شناسایی کرده‌اند، تطابق کامل دارد [۱۶]. تحلیل SHAP الگویی متفاوت از دو مخاطره دیگر را نشان داد؛ به‌گونه‌ای که چهار متغیر از هفت متغیر اصلی (لای، قطعات درشت، رس و ماسه) به ماهیت خاک مربوط بودند. این یافته با مکانیسم فیزیکی فرونشست (تراکم رسوبات آبرفتی نرم تحت اثر افت سطح آب زیرزمینی) که حق‌شانس حقیقی و همکاران (۲۰۲۱) آن را در مقیاس ملی برای ایران مستندسازی کرده‌اند، سازگار است [۱۵]. همچنین غریب‌رضا و همکاران (۲۰۲۰) در استان گلستان نقش تغییر کاربری اراضی همراه با برداشت

در نتایج این پژوهش نشان داد که الگوریتم TMGWO به‌طور سیستماتیک عملکرد مدل SVR را در مرحله آزمون بهبود بخشیده است، هرچند الگوی این بهبود در میان سه مخاطره متفاوت بود. در مدل سیلاب، الگوریتم بهینه‌سازی هر دو شاخص آموزش و آزمون را ارتقا داد (AUC-ROC از  $0/8261$  به  $0/8404$  در مرحله آزمون)؛ در حالی که برای زمین‌لغزش و فرونشست زمین، شاخص‌ها در مرحله آموزش اندکی کاهش و در مرحله آزمون به‌طور محسوس افزایش یافتند. این الگو که در ادبیات یادگیری ماشین به «کنترل بیش‌برازش» شناخته می‌شود، نشان‌دهنده توان TMGWO در افزایش تعمیم‌پذیری مدل است. این یافته با تأکید سوکرستیانی و همکاران (۲۰۲۵) بر ضرورت تنظیم فرآپارامترها [۱۰] و همچنین با نتایج بالوگان و همکاران (۲۰۲۱) و لیو و همکاران (۲۰۲۱) که برتری مدل‌های هیبریدی SVR را با الگوریتم‌های فراابتکاری گزارش کرده‌اند، کاملاً سازگار است [۶، ۹].

بررسی فرآپارامترهای بهینه‌شده (جدول ۲) نکات قابل تأملی را آشکار می‌سازد. اختلاف چشمگیر مقدار C برای زمین‌لغزش ( $44/8830$ ) نسبت به سیلاب ( $0/3056$ ) و فرونشست ( $0/4$ )، با ماهیت محلی و خوشه‌ای زمین‌لغزش‌ها در مقایسه با الگوهای پراکنده‌تر دو مخاطره دیگر سازگار است. به‌طور مشابه، تنوع مقادیر گاما در سه مخاطره (۱ برای سیلاب،  $0/0537$  برای زمین‌لغزش و  $0/1989$  برای فرونشست) نشان می‌دهد که مدل برای هر مخاطره ساختار غیرخطی متفاوتی را آموخته است. این تنوع یکی از مزایای اصلی الگوریتم‌های فراابتکاری مانند TMGWO به شمار می‌رود؛ به‌گونه‌ای که با ساختار جستجوی تطبیقی خود [۲۸، ۲۹]، قادر است برای هر مخاطره ترکیب بهینه و منحصربه‌فردی از فرآپارامترها را شناسایی کند. این رویکرد با یافته‌های بوی و همکاران (۲۰۱۹) و نگوین و همکاران (۲۰۲۱) که بهینه‌سازی هم‌زمان فرآپارامترها را برای استخراج روابط پیچیده ضروری دانسته‌اند، هم‌راستاست [۲۶، ۲۷].

## تحلیل پهنه‌بندی حساسیت سیلاب

نقشه حساسیت سیلاب، تمرکز پهنه‌های پرخطر را در نواحی کم‌ارتفاع مرکزی و دشت‌های ساحلی نشان داد، و تحلیل SHAP ارتفاع را به‌عنوان مهم‌ترین متغیر اثرگذار شناسایی کرد. این یافته با نتایج میرچولی و همکاران (۲۰۲۴) در حوضه آبخیز فامانات استان گیلان که ارتفاع و فاصله از رودخانه را به‌عنوان مؤثرترین عوامل کنترل‌کننده سیلاب گزارش کرده‌اند، انطباق دارد [۱۹]. رتبه دوم متغیر فاصله از جاده‌ها در تحلیل SHAP، که در نگاه اول غیرمنتظره به‌نظر می‌رسد، را می‌توان به همبستگی مکانی جاده‌ها با کریدورهای کم‌ارتفاع رودخانه‌ای، افزایش نفوذناپذیری سطوح در توسعه شهری و تغییر مسیر زهکشی طبیعی نسبت داد. این تفسیر با اشاره یولاه و همکاران (۲۰۲۲) به نقش فعالیت‌های انسانی در تشدید سیلاب همخوانی دارد [۸].

مقایسه شوند، داده‌های زمانی برای توسعه مدل‌های فضازمانی گنجانده شوند، و مفاهیم ریسک کامل (تلفیق حساسیت، در معرض قرارگرفتنی و آسیب‌پذیری) به‌جای صرفاً حساسیت در ارزیابی به کار رود. همچنین استفاده از روش‌های انتخاب ویژگی پیشرفته مانند Boruta-XGBoost [۴] می‌تواند کیفیت ورودی‌های مدل را بهبود بخشد.

به‌طور کلی، نتایج این پژوهش نشان می‌دهد که مدل بهینه‌سازی‌شده SVR-TMGWO نسبت به SVR پایه در مرحله آزمون عملکرد بهتری در هر سه مخاطره ارائه می‌دهد و توان تعمیم‌پذیری بالاتری دارد؛ بالاترین دقت به مخاطره فرونشست ( $AUC-ROC=0/9642$ ) و کمترین دقت به سیلاب ( $AUC-ROC=0/8404$ ) تعلق داشت؛ الگوریتم TMGWO برای هر مخاطره ترکیب منحصربه‌فردی از فرآیندها را شناسایی کرد؛ تحلیل‌های SHAP در دو مقیاس جهانی و محلی روابط فیزیکی منطقی میان متغیرها و خروجی مدل را آشکار ساخت؛ و نقشه چندمخاطره‌ای نهایی، پهنه‌های با همپوشانی دوگانه و سه‌گانه را به‌عنوان بحرانی‌ترین نواحی شناسایی کرد. در مجموع، ترکیب SVR-TMGWO با تحلیل SHAP رویکردی توانمند و قابل تفسیر برای مدل‌سازی چندمخاطره‌ای در مقیاس منطقه‌ای است که می‌تواند به‌عنوان ابزاری علمی در دست برنامه‌ریزان، مدیران بحران و سیاست‌گذاران، در جهت کاهش خسارات ناشی از مخاطرات طبیعی در استان‌های شمالی ایران به کار گرفته شود.

### مشارکت نویسندگان

در این مقاله، نویسندگان به نسبت برابر مشارکت داشته‌اند.

### تشکر و قدردانی

این اثر تحت حمایت مادی بنیاد ملی علم ایران (INSF) برگرفته شده از طرح شماره « ۴۰۴۷۰۵۶ » انجام شده است.

### تعارض منافع

«هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.»

### منابع و مآخذ

[1] Pourghasemi HR, Kariminejad N, Amiri M, Edalat M, Zarafshar M, Blaschke T, et al. Assessing and mapping multi-hazard risk susceptibility using a machine learning technique. *Sci Rep.* 2020;10(1):3203. <https://doi.org/10.1038/s41598-020-60191-3>

[2] Yousefi S, Pourghasemi HR, Emami SN, Pouyan S, Eskandari S, Tiefenbacher JP. A machine learning framework for multi-hazards modeling and mapping in a mountainous area. *Sci Rep.* 2020;10(1):12144. <https://doi.org/10.1038/s41598-020-69233-2>

[3] Karami F, Khatibi MB, Kheirizadeh M, Asl AM. Evaluation of Performance of Support Vector Machine Algorithm in Landslide Susceptibility Zoning in Ahar-chai Basin. *Journal of Geography and Environmental Hazards.* 2020;8(32):1-17. <https://doi.org/10.22067/geo.v8i4.83263>

بی‌رویه آب زیرزمینی را در تشدید فرونشست برجسته کرده‌اند [۱۱]. رفتار غیرمعمول رس در تحلیل SHAP (سهام منفی برای مقادیر بالا) را می‌توان به الگوی توزیع فضایی خاک‌های رسی نسبت داد، که در منطقه مورد مطالعه عمدتاً در نواحی دامنه‌ای و خارج از کانون‌های اصلی فرونشست متمرکز هستند؛ یافته‌ای که توان مدل SVR-TMGWO را در بازنمایی الگوی فضایی خاص منطقه (نه ارتباط عام میان رس و فرونشست) تأیید می‌کند.

### پهنه‌بندی چندمخاطره‌ای و نقش توضیح‌پذیری مدل

نقشه نهایی چندمخاطره‌ای با هشت طبقه، پهنه‌هایی با همپوشانی دوگانه و سه‌گانه را در نواحی انتقالی میان کوهستان و دشت شناسایی کرد. این پهنه‌ها از منظر مدیریت ریسک بحرانی‌ترین مناطق محسوب می‌شوند، چرا که در آن‌ها وقوع یک مخاطره می‌تواند زمینه‌ساز تشدید سایر مخاطرات شود. تفکیک فضایی واضح میان سه پهنه تک‌مخاطره (فرونشست در دشت‌های شرقی، زمین‌لغزش در پهنه‌های میان‌ارتفاع، و سیل در نوارهای ساحلی و کم‌ارتفاع) نشانه‌ای از اعتبار رویکرد مدل‌سازی است؛ بدین معنا که مدل SVR-TMGWO به‌جای آموختن یک الگوی عام «حساسیت محیطی»، توانسته است سه فرآیند فیزیکی مجزا را به‌درستی از یکدیگر تفکیک کند. این یافته با نتایج پورقاسمی و همکاران (۲۰۲۰)، یوسفی و همکاران (۲۰۲۰) و رضوی‌ترمه و همکاران (۲۰۲۵) که اهمیت ارزیابی یکپارچه مخاطرات را برجسته کرده‌اند، هم‌راستا است [۱، ۲، ۵].

تحلیل‌های SHAP در دو مقیاس جهانی و محلی، نقشی کلیدی در غلبه بر چالش «جعبه‌سیاه» مدل ایفا کردند. در سطح جهانی، رتبه‌بندی متفاوت اهمیت متغیرها برای هر مخاطره (توپوگرافی-هیدرولوژیکی برای سیل، توپوگرافی-شیب-خاک برای زمین‌لغزش، و خصوصیات خاک‌شناختی برای فرونشست) تأییدی قوی بر این واقعیت است که مدل به‌جای پیش‌بینی الگوی عام مخاطره، فیزیک مجزای هر یک را آموخته است. در سطح محلی، نقشه‌های SHAP علاوه بر اعتبارسنجی مکانی مدل، ابزاری برای مدیریت ریسک محلی فراهم می‌آورند که با شاخص‌های آماری معرفی‌شده توسط مرغادی و همکاران (۲۰۲۰) و هوانگ و همکاران (۲۰۲۰) تکمیل می‌گردند [۳۰، ۳۱].

### نتیجه‌گیری و پیشنهادها

با وجود نتایج رضایت‌بخش، این پژوهش دارای محدودیت‌هایی است. ایستا در نظر گرفتن تمامی متغیرها، عدم لحاظ صریح داده‌های افت سطح آب زیرزمینی (برای فرونشست) و داده‌های بارش (برای سیلاب)، و عدم در نظر گرفتن تعاملات زمانی میان مخاطرات، از مهم‌ترین این محدودیت‌ها هستند. برای پژوهش‌های آتی پیشنهاد می‌شود که مدل‌های یادگیری عمیق (مانند CNN که توسط یولاه و همکاران (۲۰۲۲) موفقیت‌آمیز گزارش شده [۸]) با رویکرد SVR-TMGWO

- Method in Arabdagh forests of Iran. *Environmental Resources Research*. 2022;10(2):165–82.  
<https://doi.org/10.22069/ijerr.2023.18630.1326>
- [15] Haghshenas Haghghi M, Motagh M. Land Subsidence Hazard in Iran Revealed by Country-Scale Analysis of Sentinel-1 Insar. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2021;XLIII-B3-2021:155–61.  
<https://doi.org/10.5194/isprs-archives-XLIII-B3-2021-155-2021>
- [16] Haghshenas Haghghi M, Motagh M. Uncovering the impacts of depleting aquifers: A remote sensing analysis of land subsidence in Iran. *Sci Adv*. 2024;10(19):eadk3039.  
<https://doi.org/10.1126/sciadv.adk3039>
- [17] Pourghasemi HR, Pradhan B, Gokceoglu C. Application of fuzzy logic and analytical hierarchy process (AHP) to landslide susceptibility mapping at Haraz watershed, Iran. *Natural hazards*. 2012;63(2):965–96.  
<https://doi.org/10.1007/s11069-012-0217-2>
- [18] Bahrami Y, Hassani H, Maghsoudi A. Landslide susceptibility mapping using AHP and fuzzy methods in the Gilan province, Iran. *Geojournal*. 2021;86(4):1797–816.  
<https://doi.org/10.1007/s10708-020-10162-y>
- [19] Mirchooli F, Gholami I, Boroughani M. Flood Susceptibility Mapping of the Farnat Watershed, Gilan Province. *Water and Soil*. 2024;37(6):841–53.  
<https://doi.org/10.22067/jsw.2023.84146.1328>
- [20] Aditian A, Kubota T, Shinohara Y. Comparison of GIS-based landslide susceptibility models using frequency ratio, logistic regression, and artificial neural network in a tertiary region of Ambon, Indonesia. *Geomorphology*. 2018;318:101–11.  
<https://doi.org/10.1016/j.geomorph.2018.06.006>
- [21] Zevenbergen LW, Thorne CR. Quantitative analysis of land surface topography. *Earth surface processes and landforms*. 1987;12(1):47–56.  
<https://doi.org/10.1002/esp.3290120107>
- [22] Rahmati O, Falah F, Naghibi SA, Biggs T, Soltani M, Deo RC, et al. Land subsidence modelling using tree-based machine learning algorithms. *Science of the total environment*. 2019;672:239–52.  
<https://doi.org/10.1016/j.scitotenv.2019.03.496>
- [23] Nguyen HD, Dang DK, Bui QT, Petrisor AI. Multi-hazard assessment using machine learning and remote sensing in the North Central region of Vietnam. *Transactions in GIS*. 2023;27(5):1614–40.  
<https://doi.org/10.1111/tgis.13091>
- [24] Moayedi H, Mosallanezhad M, Rashid ASA, Jusoh WAW, Muazu MA. A systematic review and meta-analysis of artificial neural network application in geotechnical engineering: theory and applications. *Neural Computing and Applications*. 2020;32(2):495–518.  
<https://doi.org/10.1007/s00521-019-04109-9>
- [25] Duan K, Keerthi SS, Poo AN. Evaluation of simple performance measures for tuning SVM hyperparameters. *Neurocomputing*. 2003;51:41–59.
- [4] Yousefi Z, Alesheikh AA, Jafari A, Torktatari S, Sharif M. Stacking Ensemble Technique Using Optimized Machine Learning Models with Boruta–XGBoost Feature Selection for Landslide Susceptibility Mapping: A Case of Kermanshah Province, Iran. *Information*. 2024;15(11):689.  
<https://doi.org/10.3390/info15110689>
- [5] Razavi-Termeh SV, Sadeghi-Niaraki A, Ali F, Pradhan B, Choi SM. Optimizing ensemble learning for satellite-based multi-hazard monitoring and susceptibility assessment of landslides, land subsidence, floods, and wildfires. *Sci Rep*. 2025;15(1):30968.  
<https://doi.org/10.1038/s41598-025-15381-2>
- [6] Liu R, Peng J, Leng Y, Lee S, Panahi M, Chen W, et al. Hybrids of support vector regression with grey wolf optimizer and firefly algorithm for spatial prediction of landslide susceptibility. *Remote Sensing*. 2021;13(24):4966.  
<https://doi.org/10.3390/rs13244966>
- [7] Khatakho R, Gautam D, Aryal KR, Pandey VP, Rupakhety R, Lamichhane S, et al. Multi-Hazard Risk Assessment of Kathmandu Valley, Nepal. *Sustainability*. 2021;13(10):5369.  
<https://doi.org/10.3390/su13105369>
- [8] Ullah K, Wang Y, Fang Z, Wang L, Rahman M. Multi-hazard susceptibility mapping based on Convolutional Neural Networks. *Geoscience Frontiers*. 2022;13(5):101425.  
<https://doi.org/10.1016/j.gsf.2022.101425>
- [9] Balogun A-L, Rezaie F, Pham QB, Gigović L, Drobnjak S, Aina YA, et al. Spatial prediction of landslide susceptibility in western Serbia using hybrid support vector regression (SVR) with GWO, BAT and COA algorithms. *Geoscience Frontiers*. 2021;12(3):101104.  
<https://doi.org/10.1016/j.gsf.2020.10.009>
- [10] Sukristiyanti S, Pamela P, Putra MHZ, Arifianti Y, Rozie AF, Lestiana H, et al. Hyperparameter Tuning on Machine Learning-Based Landslide Susceptibility Mapping (Case study: Palu City and Its Surrounding areas). *Indonesian Journal on Geoscience*. 2025;12(1):43–53.  
<https://doi.org/10.17014/ijog.12.1.43-53>
- [11] Gharibreza M, Zaman M, Porto P, Fulajtar E, Parsaei L, Eisaei H. Assessment of deforestation impact on soil erosion in loess formation using 137Cs method (case study: Golestan Province, Iran). *International Soil and Water Conservation Research*. 2020;8(4):393–405.  
<https://doi.org/10.1016/j.iswcr.2020.07.006>
- [12] Arabameri A, Saha S, Roy J, Chen W, Blaschke T, Tien Bui D. Landslide Susceptibility Evaluation and Management Using Different Machine Learning Methods in The Gallicash River Watershed, Iran. *Remote Sensing*. 2020;12(3):475.  
<https://doi.org/10.3390/rs12030475>
- [13] Pourghasemi HR, Jirandeh AG, Pradhan B, Xu C, Gokceoglu C. Landslide susceptibility mapping using support vector machine and GIS at the Golestan Province, Iran. *Journal of Earth System Science*. 2013;122(2):349–69.  
<https://doi.org/10.1007/s12040-013-0282-2>
- [14] Mastouri A, Shataee S, Moayeri MH, Maghsoudi Y. Landslide susceptibility mapping using GIS-Based-MCDM

[37] Rodríguez-Pérez R, Bajorath J. Interpretation of machine learning models using shapley values: application to compound potency and multi-target activity predictions. *Journal of computer-aided molecular design*. 2020;34(10):1013–26. <https://doi.org/10.1007/s10822-020-00314-0>

[38] Mohammady M, Pourghasemi HR, Amiri M. Assessment of land subsidence susceptibility in Semnan plain (Iran): a comparison of support vector machine and weights of evidence data mining algorithms. *Natural hazards*. 2019;99(2):951–71. <https://doi.org/10.1007/s11069-019-03785-z>

## معرفی نویسندگان

### AUTHOR(S) BIOSKETCHES



**کیمیا خیرخواه** ایشان دانشجوی کارشناسی ارشد رشته سیستم‌های اطلاعات مکانی در دانشگاه صنعتی خواجه نصیرالدین طوسی می‌باشند. ایشان مدرک کارشناسی خود را در سال ۱۴۰۲ از همین دانشگاه اخذ نمودند و حوزه فعالیت ایشان هوش مصنوعی توضیح‌پذیر و مدل‌سازی مخاطرات محیطی می‌باشد. در حال حاضر، پژوهش ایشان بر کاربرد روش‌های یادگیری ماشین و Explainable AI در نقشه‌سازی حساسیت چندمخاطره متمرکز است.

**Kheirkhah, K. Master of Science Student in the Department of Geospatial Information Systems, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran**

[kimyakheirkhah@email.kntu.ac.ir](mailto:kimyakheirkhah@email.kntu.ac.ir)



**علی اصغر آل شیخ** ایشان استاد تمام گروه سیستم‌های اطلاعات مکانی دانشکده مهندسی ژئودزی و ژئوماتیک دانشگاه صنعتی خواجه نصیرالدین طوسی می‌باشند. ایشان دارای مدرک دکترای تخصصی در رشته مهندسی سیستم‌های اطلاعات مکانی (GIS) از دانشگاه

کلگری کانادا در سال ۱۳۷۷ می‌باشند. همچنین جوایز و افتخارات متعددی برای مشارکت‌های علمی و دانشگاهی کسب کرده‌اند. مقالات بسیاری در مجلات معتبر خارجی و داخلی توسط ایشان در زمینه‌های مختلف همچون سیستم‌های اطلاعات مکانی، GIS تحت وب، مکان‌یابی، هوش مصنوعی، Health GIS و ... به چاپ رسیده است.

**Alesheikh, A. Full Professor at the Department of Geospatial Information Systems, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran**

[alesheikh@kntu.ac.ir](mailto:alesheikh@kntu.ac.ir)

[https://doi.org/10.1016/S0925-2312\(02\)00601-X](https://doi.org/10.1016/S0925-2312(02)00601-X)

[26] Bui DT, Tsangaratos P, Nguyen V-T, Van Liem N, Trinh PT. Comparing the prediction performance of a Deep Learning Neural Network model with conventional machine learning models in landslide susceptibility assessment. *Catena*. 2020;188:104426. <https://doi.org/10.1016/j.catena.2019.104426>

[27] Nguyen H, Mehrabi M, Kalantar B, Moayedi H, Abdullahi MaM. Potential of hybrid evolutionary approaches for assessment of geo-hazard landslide susceptibility mapping. *Geomatics, Natural Hazards and Risk*. 2019. <https://doi.org/10.1080/19475705.2019.1607782>

[28] Mirjalili S, Mirjalili SM, Lewis A. Grey Wolf Optimizer. *Advances in Engineering Software*. 2014;69:46–61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>

[29] Abdel-Basset M, El-Shahat D, El-henawy I, de Albuquerque Victor Hugo C, Mirjalili S. A new fusion of grey wolf optimizer algorithm with a two-phase mutation for feature selection. *Expert Systems with Applications*. 2020;139:112824. <https://doi.org/10.1016/j.eswa.2019.112824>

[30] Merghadi A, Yunus AP, Dou J, Whiteley J, ThaiPham B, Bui DT, et al. Machine learning methods for landslide susceptibility studies: A comparative overview of algorithm performance. *Earth-Science Reviews*. 2020;207:103225. <https://doi.org/10.1016/j.earscirev.2020.103225>

[31] Huang F, Cao Z, Guo J, Jiang S-H, Li S, Guo Z. Comparisons of heuristic, general statistical and machine learning models for landslide susceptibility prediction and mapping. *Catena*. 2020;191:104580. <https://doi.org/10.1016/j.catena.2020.104580>

[32] Moayedi H, Mehrabi M, Mosallanezhad M, Rashid ASA, Pradhan B. Modification of landslide susceptibility mapping using optimized PSO-ANN technique. *Engineering with Computers*. 2019;35(3):967–84. <https://doi.org/10.1007/s00366-018-0644-0>

[33] Pham BT, Avand M, Janizadeh S, Phong TV, Al-Ansari N, Ho LS, et al. GIS Based Hybrid Computational Approaches for Flash Flood Susceptibility Assessment. *Water*. 2020;12(3):683. <https://doi.org/10.3390/w12030683>

[34] Chicco D, Warrens MJ, Jurman G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Comput Sci*. 2021;7:e623. <https://doi.org/10.7717/peerj-cs.623>

[35] Lundberg SM, Lee S-I. A unified approach to interpreting model predictions. *Advances in neural information processing systems*. 2017;30. <https://dl.acm.org/doi/10.5555/3295222.3295230>

[36] Molnar C. Interpretable machine learning. *Lulu com*. 2020.


چالش‌ها در حوزه مطالعه مخاطرات طبیعی، محیط زیست، علوم زمین و مدیریت بحران است.

**Rezaie, F. Postdoc Researcher in the Department of Geospatial Information Systems, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran**  
 [frezaie@kntu.ac.ir](mailto:frezaie@kntu.ac.ir)



**مهدی پناهی** پژوهشگر در حوزه مدل‌سازی مخاطرات طبیعی و کاربردهای هوش مصنوعی در مطالعات محیط‌زیستی هستند. ایشان مدرک دکترای تخصصی خود را در رشته نقشه برداری از دانشگاه ملی کانگوون کره جنوبی دریافت کرده و دوره‌های

پسادکتری خود را در مؤسسات تراز اول بین‌المللی، از جمله دانشگاه یانسه (Yonsei) کره جنوبی و دانشگاه استکهلم سوئد، سپری نموده‌اند. تمرکز فعالیت‌های علمی ایشان بر تلفیق الگوریتم‌های مبتنی بر هوش مصنوعی با تحلیل‌های مکان‌مند به منظور درک عمیق‌تر و مدیریت بهینه مخاطرات طبیعی استوار است.

**Panahi, M. Department of Physical Geography and Bolin Centre for Climate Research, Stockholm University, Stockholm, Sweden**  
 [mahdi.panahi@natgeo.su.se](mailto:mahdi.panahi@natgeo.su.se)



**علی جعفری** پژوهشگر حوزه سیستم‌های اطلاعات مکانی و دانشجوی دکتری در گروه GIS، دانشکده مهندسی ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران است. او مدرک کارشناسی خود را در رشته مهندسی ژئوماتیک از دانشگاه اصفهان و مدرک کارشناسی ارشد خود را در رشته سیستم‌های اطلاعات مکانی از دانشگاه تهران دریافت کرده است. تمرکز اصلی پژوهش‌های او بر توسعه و به‌کارگیری سیستم‌های اطلاعات مکانی با هدف بهینه‌سازی مدل‌های یادگیری ماشین برای حل مسائل مکانی است. زمینه‌های پژوهشی وی شامل داده‌کاوی فضایی، یادگیری ماشین، بهینه‌سازی و الگوریتم‌های فراابتکاری، آمار فضایی و تصمیم‌گیری چندمعیاره مبتنی بر GIS است.

**Jafari, A. PhD of Science Student in the Department of Geospatial Information Systems, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran**  
 [alijafari7525@gmail.com](mailto:alijafari7525@gmail.com)



**فاطمه رضائی** پژوهشگر پسادکتر حوزه سیستم‌های اطلاعات مکانی در دانشگاه صنعتی خواجه نصیرالدین طوسی است. محور اصلی فعالیت‌های ایشان بر تلفیق الگوریتم‌های مبتنی بر هوش مصنوعی با تحلیل‌های مکان‌مند (Geospatial Analysis)، جهت حل

Citation (Vancouver): Kheirkhah K, AleSheikh AA, Jafari A, Rezaie F, Panahi M. [Development of Optimized Explainable Machine Learning Models for Preparing Multi-Hazard Susceptibility Maps of Flood, Landslide, and Land Subsidence (Case Study: Caspian Sea Coast)]. *J. RS. GEOINF. RES.* 2026; 4(1): 83-106

 <https://doi.org/10.22061/jrsg.2026.113132.1131>



**COPYRIGHTS**

© 2026 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0)  
[\(https://creativecommons.org/licenses/by-nc/4.0/\)](https://creativecommons.org/licenses/by-nc/4.0/)