



پیش بینی حساسیت به زمین لغزش حوزه آبخیز پلرود با روش های یادگیری ماشین

مرضیه حیدری^۱، علی فضل الهی^۲، سید پدرام نیوآ^۳

۱- دانشجوی کارشناسی ارشد، گروه مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه گیلان، صومعه سرا، ایران.

۲- استادیار، گروه مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه گیلان، صومعه سرا، ایران.

۳- دکتری علوم و مهندسی آبخیزداری (حفاظت آب و خاک)، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران.

اطلاعات مقاله	چکیده
نوع مقاله: پژوهشی	زمین لغزش یکی از مهم ترین مخاطرات ژئومورفولوژیکی است که تهدیدی جدی برای منابع طبیعی، زیرساخت ها و سکونت گاه های انسانی محسوب می شود. هدف این پژوهش، پهنه بندی حساسیت زمین لغزش در حوزه آبخیز پلرود با استفاده از الگوریتم های یادگیری ماشین و ارزیابی تطبیقی عملکرد آن ها بود. بدین منظور، سه الگوریتم جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM) و درخت تصمیم (DT) به کار گرفته شد و ۱۹ متغیر مؤثر در قالب عوامل توپوگرافی، هیدرولوژیکی و محیطی - انسانی در فرایند مدل سازی مورداستفاده قرار گرفت. داده های رخداد زمین لغزش به صورت تصادفی به دو بخش ۷۰ درصد برای آموزش و ۳۰ درصد برای ارزیابی مدل ها تقسیم شدند. عملکرد مدل ها با استفاده از شاخص هایی، شامل سطح زیر منحنی (AUC)، دقت کلی، حساسیت، ویژگی، صحت، ضریب همبستگی R، امتیاز F1، CV-ROC و ضریب کاپا ارزیابی شد. نتایج نشان داد الگوریتم RF نسبت به سایر مدل ها توان بالاتری در شناسایی الگوی مکانی حساسیت زمین لغزش داشته و با ارائه توزیع واقع بینانه تر از پهنه های پرخطر، حدود ۲۴ درصد از مساحت حوضه را در کلاس حساسیت زیاد طبقه بندی کرد. لذا، مقدار AUC برابر ۰/۷۵ و CV-ROC برابر ۰/۹۷ بیانگر پایداری مناسب مدل است، هرچند دقت کلی ۰/۶۲ اثر نامتوازن بودن داده ها را نشان می دهد. در مقابل، مدل SVM گرایش بیشتری به طبقه بندی نواحی کم خطر داشت و مدل DT پایداری کمتری نشان داد. تحلیل اهمیت متغیرها نقش برجسته شاخص های مورفومتری TRI و TPI و متغیرهای هیدرولوژیکی SPI و CN را در کنترل ناپایداری دامنه ها تأیید کرد. در مجموع، نتایج پژوهش برتری الگوریتم RF و کارایی و قابلیت اطمینان بیشتر آن در پهنه بندی حساسیت زمین لغزش را تأیید می کند.
تاریخ دریافت: ۱۴۰۴/۱۰/۰۸	
تاریخ پذیرش: ۱۴۰۵/۰۲/۲۲	
دسترسی آنلاین: ۱۴۰۵/۰۲/۳۰	
کلید واژه ها: پهنه بندی، جنگل تصادفی، سامانه اطلاعات جغرافیایی (GIS)، مخاطرات طبیعی، ناپایداری دامنه ها	



Prediction of Landslide Susceptibility in the Polroud Watershed Using Machine Learning Methods

Marziyeh Heydari¹, Ali Fazlollahi^{2✉}, Seyed Pedram Nainiva³

- 1- M.Sc. Student, Department of Rang and Watershed Management, Faculty of Natural Resources, University of Guilan, Sowmehsara, Iran.
- 2- Assistant Professor, Department of Rang and Watershed Management, Faculty of Natural Resources, University of Guilan, Sowmehsara, Iran.
- 3- Ph.D. in Watershed Management, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran.

Article Info	Abstract
Article type: Research Article	Landslides are among the most significant geomorphological hazards, posing a serious threat to natural resources, infrastructure, and human settlements. The aim of this study was to perform landslide susceptibility zonation in the Polrud Watershed using machine learning algorithms and to evaluate their performance comparatively. For this purpose, three machine learning algorithms—Random Forest (RF), Support Vector Machine (SVM), and Decision Tree (DT)—were employed, and 19 landslide conditioning factors, categorized into topographic, hydrological, and environmental–anthropogenic groups, were utilized in the modeling process. The landslide inventory data were randomly divided into training (70%) and testing (30%) datasets for model evaluation. The performance of the models was evaluated using metrics including the Area Under the Curve (AUC), overall accuracy, sensitivity, specificity, precision, correlation coefficient (R), F1-score, CV-ROC, and Cohen's kappa coefficient. The results showed that the RF algorithm outperformed the other models in identifying the spatial pattern of landslide susceptibility and, by providing a more realistic distribution of high-susceptibility zones, classified approximately 24% of the watershed area as high susceptibility. Accordingly, the AUC value of 0.75 and CV-ROC of 0.97 indicate appropriate model stability, although the overall accuracy of 0.62 reveals the impact of data imbalance. In contrast, the SVM model showed a greater tendency to classify areas as low susceptibility, whereas the DT model exhibited lower stability. Variable importance analysis confirmed the prominent role of the morphometric indices TRI and TPI, as well as the hydrological variables SPI and CN, in controlling slope instability. Overall, the research results confirm the superiority of the RF algorithm and its greater efficiency and reliability in landslide susceptibility zonation.
Article history:	
Received: 2025/12/29	
Accepted: 2026/05/12	
Available online: 2026/05/20	
Keywords: Zonation, Random Forest, Geographic Information System (GIS), Natural Hazards, Slope Instability	

✉ Corresponding author E-mail address: Ali.Fazlollahi79@gmail.com

مقدمه

زمین لغزش به عنوان یکی از مخرب ترین مخاطرات زمین شناسی، تهدیدی جدی برای جوامع انسانی، زیرساخت های حیاتی و پایداری محیط زیست در بسیاری از مناطق جهان به شمار می رود (أبدو و ریچی^۱، ۲۰۲۴). این پدیده ناشی از جابه جایی توده های خاک و سنگ در امتداد شیب تحت تأثیر نیروی جاذبه بوده و زمانی رخ می دهد که تنش های وارده بر مواد سطحی از مقاومت برشی آن ها فراتر رود (لین^۲ و همکاران، ۲۰۱۷).

در مقیاس جهانی، زمین لغزش از نظر خسارات مالی و تلفات انسانی در میان بلایای طبیعی جایگاه قابل توجهی دارد و پیامدهای آن شامل تخریب زیرساخت ها، اختلال در شبکه های حمل و نقل و تحمیل هزینه های اقتصادی سنگین است (ژو^۳ و همکاران، ۲۰۲۳). در ایران، پیچیدگی ساختار زمین شناسی، توپوگرافی ناهموار، گسترش فعالیت های انسانی و ضعف های مدیریتی موجب شده است بخش وسیعی از مناطق کوهستانی کشور در معرض خطر بالای زمین لغزش قرار گیرند (فاطمی آقدا^۴ و همکاران، ۲۰۱۸). حدود یک سوم مساحت ایران کوهستانی است و نواحی شمالی، به ویژه دامنه های البرز، بیشترین آسیب پذیری را تجربه می کنند (هفت لنگ و لانگ^۵، ۲۰۰۳). بر اساس گزارش کمیته ملی کاهش بلایای طبیعی وزارت کشور، خسارت مستقیم سالانه زمین لغزش در ایران حدود ۵۰۰ میلیارد ریال برآورد شد، در حالی که اثرات غیرمستقیم آن نظیر فرسایش خاک، افزایش رسوب گذاری و تخریب اکوسیستم ها، هزینه های واقعی را به مراتب افزایش خواهد داد (عرب عامری^۶ و همکاران، ۲۰۲۰).

ماهیت چندعاملی زمین لغزش و کنش متقابل پیچیده عوامل زمین شناسی، توپوگرافی، اقلیمی و انسانی موجب شده است که روش های سنتی همواره دقت لازم را در پیش بینی نواحی مستعد ناپایداری نداشته باشند (وانگ^۷ و همکاران، ۲۰۱۹). همچنین در دهه های اخیر، مدل های یادگیری ماشین به دلیل توانایی بالا در شناسایی الگوهای پیچیده و روابط غیرخطی میان متغیرها، به طور گسترده در مطالعات زمین لغزش به کار گرفته شده اند. بخشی از این مطالعات که بر داده های سنجش از دور و فناوری های نوین متکی بوده اند، شامل وانگ و همکاران (۲۰۱۹)؛ اکبر و ها^۸ (۲۰۱۱) کوهنل^۹ و همکاران (۲۰۲۳) و چوئی^{۱۰} و همکاران (۲۰۲۴) است. در مقابل، گروهی از پژوهش ها مانند مطالعات پندی^{۱۱} و همکاران (۲۰۰۸)؛ حجازی (۱۳۹۳)؛ دسترنج و همکاران، ۱۴۰۳ مبتنی بر داده های مکانی و مدل سازی در محیط GIS انجام شده است. همچنین، روش های آماری و تصمیم گیری چندمعیاره نظیر رگرسیون لجستیک، تحلیل سلسله مراتبی فازی و الگوریتم های مانند MABAC^{۱۲} و CODAS^{۱۳} نیز در برخی مطالعات نظیر فیض نیا و همکاران (۱۳۸۰)؛ مددی و همکاران (۱۳۹۹) به کار رفته اند. در نهایت، گروهی از مطالعات اخیر با تمرکز بر الگوریتم های یادگیری ماشین و رویکردهای ترکیبی پیشرفته انجام شده است؛ از جمله پاتل^{۱۴} و همکاران (۲۰۲۴) که مجموعه ای از مدل ها شامل RF^{۱۵}، AdaBoostM1، Vote، Stacking و Bagging را به کار گرفته اند، و پژوهش شهابی^{۱۶} و

1- Abdo & Richi

2- Lin

3- Zhuo

4- Fatemi Aghda

5- Haftlang & Lang

6- Arabameri

7- Wang

8- Akbar & Ha

9- Kühnl

10- Cui

11- Pandey

12- Multiple Criteria Decision-Making (MCDM)

13- Combinative Distance-based ASsessment (CODAS)

14- Patel

15- Random Forest (RF)

16- Shahabi

همکاران (۲۰۲۳) و ساداتی و همکاران (۱۴۰۴) اثربخشی الگوریتم‌هایی چون SVM^۱، RF و DT^۲ را در تحلیل و نقشه‌برداری حساسیت زمین‌لغزش تأیید کردند.

باوجود این، پیشرفت‌ها، حوزه آبخیز پلرود که در دهه‌های اخیر رخدادهای مکرر سیلاب و زمین‌لغزش را تجربه کرده است، تاکنون در ادبیات علمی مرتبط با ارزیابی حساسیت زمین‌لغزش موردتوجه قرار نگرفت؛ زیرا فقدان بانک داده تاریخی منسجم، نقشه‌های دقیق رخداد و اطلاعات ژئومورفولوژیکی معتبر، موجب ایجاد شکاف پژوهشی و تحلیل دقیق در شناخت الگوی مکانی لغزش‌ها در این حوضه شده است. براین اساس، نوآوری پژوهش حاضر در به‌کارگیری یک چارچوب ارزیابی مبتنی بر یادگیری ماشین جهت مقایسه عملکرد مدل‌های پیشرفته در محیطی فاقد پیشینه پژوهشی نهفته است؛ این مطالعه برای نخستین‌بار، کارایی سه الگوریتم کلیدی یادگیری ماشین را به همراه مجموعه‌ای گسترده از متغیرها را در این حوضه مورد مقایسه و ارزیابی قرار می‌دهد. رویکردی که می‌تواند با تلفیق داده‌های محیطی جامع موجود و روش‌های داده‌محور، چارچوبی نظام‌مند برای شناسایی و پشتیبانی از مدیریت خطر زمین‌لغزش در حوضه پلرود فراهم آورد.

مواد و روش

• منطقه مورد مطالعه

حوزه آبخیز پلرود، بزرگ‌ترین حوضه استان گیلان، در محدوده طول‌های جغرافیایی ۴۹ درجه و ۴۵ دقیقه تا ۵۰ درجه و ۳۰ دقیقه و عرض‌های ۳۶ درجه و ۳۷ دقیقه تا ۳۷ درجه و ۸ دقیقه شمالی واقع شده و بخش قابل‌توجهی از دامنه‌های شمالی ارتفاعات البرز مرکزی، شامل ارتفاعات جنوب و غرب دیلمان را پوشش می‌دهد. این حوضه با مساحت ۱۷۶۱۶۸/۳ هکتار، دارای رودخانه‌ای به طول تقریباً ۶۹/۱ کیلومتر است که از جنوب به شمال جریان یافته و نهایتاً به دریای کاسپین وارد می‌شود. متوسط جریان سالیانه پلرود حدود ۴۷۱/۹ میلیون مترمکعب برآورد شده است. از منظر زمین‌شناسی، عرصه‌های مختلف حوضه متشکل از سازنده‌های متعلق به دوران مزوزوئیک، پالئوزوئیک و سنوزوئیک است که تنوع لیتولوژی و ساختارهای تکتونیکی آن، نقش مهمی در شکل‌گیری الگوهای ناپایداری دامنه‌ها ایفا می‌کند. بر اساس داده‌های هواشناسی، اقلیم منطقه در طبقه معتدل و مرطوب قرار می‌گیرد. این حوضه با بیش از ۳۸۷ آبادی، جمعیتی حدود ۱۲۳۰۹۴ نفر را در خود جای داده است و بخش عمده‌ای از اراضی شالی‌کاری منطقه از منابع آب پلرود تغذیه می‌شوند. موقعیت جغرافیایی و گستره منطقه مورد مطالعه در شکل (۱) نمایش داده شده است.

1- Support Vector Machine (SVM)

2- Decision Tree (DT)

جدول (۱) عوامل مؤثر در وقوع زمین‌لغزش

متغیرهای مؤثر	نحوه تهیه	علت انتخاب
شیب و جهت شاخص رطوبت توپوگرافی (TWI) ^۷ ارتفاع انحنا شاخص موقعیت توپوگرافیکی (TPI) ^۸ شاخص ناهمواری زمین (TRI) ^۹	کلیه عوامل فیزیوگرافی مورد استفاده در این پژوهش بر پایه مدل رقومی ارتفاع (DEM) با قدرت تفکیک ۳۰ متر، استخراج شده از داده‌های SRTM در سامانه Google Earth Engine تهیه شدند. لایه شیب و جهت شیب و انحنا در محیط ArcMap و با ابزار Spatial Analyst تهیه شدند. شاخص رطوبت توپوگرافی (TWI) نیز بر اساس DEM حوضه و مطابق رابطه $TWI = \ln\left(\frac{\alpha}{\tan\beta}\right)$ در نرم‌افزار ArcMap محاسبه شد. شاخص موقعیت توپوگرافیکی (TPI) و شاخص ناهمواری توپوگرافی (TRI) نیز با استفاده از DEM حوضه با ابزار Morphometry در نرم‌افزار SAGA GIS و بر اساس روابط $TPI = Z_0 - \left(\sum_{i=1}^n Z_i / n\right)$ $TRI = \left(\sum (Z_c - Z_i)^2\right)^{1/2}$ محاسبه شدند.	عوامل فیزیوگرافی متعددی در وقوع زمین‌لغزش دخیل هستند. ارتفاع (زارع ^۱ و همکاران، ۲۰۱۳)، جهت و شیب (مجددی ^۲ و همکاران، ۲۰۱۷؛ عرب عامری و همکاران، ۲۰۲۰)، انحنا (پردهان ^۳ ۲۰۱۱)، شاخص رطوبت توپوگرافی (ملس ^۴ و همکاران، ۲۰۲۰)، شاخص موقعیت توپوگرافیکی (سلامی و رهینان ^۵ ، ۲۰۲۴) و شاخص ناهمواری توپوگرافی (توفیق‌اسلام ^۶ و همکاران، ۲۰۲۱) که همگی بر شرایط توپوگرافی و اقلیمی اثرگذار هستند و رابطه مستقیمی با زمین‌لغزش دارد. این عوامل به‌طور کلی بر ناپایداری دامنه‌ها و احتمال وقوع زمین‌لغزش تأثیر می‌گذارند.
کاربری اراضی فاصله از جاده و تراکم جاده شاخص نرمال شده تفاوت پوشش گیاهی (NDVI) ^{۱۲} زمین‌شناسی فاصله از گسل و تراکم گسل	نقشه کاربری اراضی با مقیاس ۱:۲۵۰۰۰ از سازمان جهاد کشاورزی استان گیلان، متغیرهای فاصله از جاده و تراکم جاده‌ها با استفاده از نقشه مسیرهای ارتباطی استان گیلان (دریافتی از اداره راه و شهرسازی)، فاصله از گسل و تراکم گسل‌ها با استفاده از نقشه گسل‌های استان گیلان (دریافتی از اداره منابع طبیعی و آبخیزداری) و نقشه‌های زمین‌شناسی منطقه نیز از اداره زمین‌شناسی و اکتشافات معدنی استان با مقیاس ۱:۱۰۰۰۰۰ دریافت شد. همچنین شاخص نرمال شده تفاوت پوشش گیاهی (NDVI)، باتوجه به زمان وقوع زمین‌لغزش‌ها طی دوره آماری ۳۰ ساله در حوضه، با استفاده از تصاویر ماهواره‌ای لندست در سامانه Google Earth Engine (GEE) و بر اساس رابطه $NDVI = (NIR - R) / (NIR + R)$ محاسبه گردید. ضمناً پردازش تمامی نقشه‌ها و کلاسه‌بندی‌ها در محیط ArcMap صورت گرفت.	عوامل محیطی و انسانی در این مطالعه بر اساس اهمیت و تأثیرگذاری آن‌ها انتخاب شده‌اند. کاربری اراضی (دسترنج و کریمی سنگچینی، ۱۴۰۱)، فاصله و تراکم جاده‌ها (ساداتی و همکاران، ۱۴۰۴)، شاخص نرمال شده تفاوت پوشش گیاهی (آلگری ^{۱۰} و همکاران، ۲۰۲۴) سازنده‌های زمین‌شناسی (یو ^{۱۱} و همکاران، ۲۰۲۳) و در نهایت، گسل‌ها به‌عنوان نشانگرهای اصلی فعالیت‌های تکتونیکی، با ایجاد ضعف ساختاری و افزایش ناپایداری ژئومکانیکی، به طور قابل توجهی احتمال وقوع زمین‌لغزش را در مناطق اطراف خود افزایش می‌دهند، لذا متغیرهای فاصله و تراکم گسل‌ها به همین سبب در تحلیل لحاظ شدند (ساداتی و همکاران، ۱۴۰۴).

1- Zare

2- Mojaddadi

3- Pradhan

4- Meles

5- Sellami & Rhinane

6- Towfiqul Islam

7- Topographic Wetness Index (TWI)

8- Topographic Position Index (TPI)

9- Terrain Rugedness Index (TRI)

10- Allegri

11- Yu

12- Normalized Difference Vegetation Index (NDVI)

متغیرهای موثر	نحوه تهیه	علت انتخاب
بارش فاصله تا آبراهه و تراکم آبراهه شماره منحنی (CN) ^۲ شاخص قدرت جریان (SPI) ^۳	داده‌های بارش از طریق آمار ایستگاه‌های باران‌سنجی واقع در حوضه، از شرکت آب منطقه‌ای استان تهیه شد. نقشه‌های مربوط به آبراهه‌ها به وسیله الحاقیه Arc hydro در محیط ArcMap تهیه و کلاس‌بندی شد. نقشه CN بر اساس نقشه کاربری اراضی و نقشه خاک حوضه در محیط ArcMap تهیه شد. همچنین، تهیه نقشه SPI به وسیله DEM حوضه پلرود در نرم‌افزار ArcMap انجام شد و محاسبات به وسیله رابطه: $SPI = A_s \tan \beta$ صورت گرفت.	باران به عنوان یک عامل محرک کلیدی، نقش محوری در تشدید زمین لغزش دارد (طالبی و همکاران، ۱۳۸۸). نزدیکی به آبراهه‌ها و افزایش تراکم شبکه‌های زهکشی، شماره منحنی (نورالهی و سید کابلی ^۱ ، ۲۰۲۱) همگی نشان‌دهنده واکنش حوضه آبخیز به بارندگی و تولید رواناب، همچنین ایجاد فرسایش، زیرشویی دلالت دارند. SPI نیز، قدرت فرسایش جریان آب را نشان می‌دهد (بابلی مؤخر و همکاران، ۱۳۹۷).

• نقاط زمین لغزش و نقاط عدم زمین لغزش

در این مطالعه تهیه نقشه حساسیت به زمین لغزش بر اساس نقاط رخداد تاریخی سه دهه اخیر که توسط اداره کل منابع طبیعی و آبخیزداری استان گیلان گردآوری شده بود، انجام گرفت و نقاط عدم زمین لغزش نیز به وسیله تصاویر ماهواره‌ای گوگل ارث تعیین شد (شکل ۲).



(پ)



(ب)



(الف)



(ج)



(ث)



(ت)

شکل (۲) تصاویر (الف تا ج) نمونه‌هایی از وقوع زمین لغزش در منطقه مورد مطالعه

• الگوریتم‌های یادگیری ماشین

انتخاب الگوریتم مناسب در یادگیری ماشین بستگی به عوامل متعددی دارد؛ چرا که یادگیری ماشین از الگوریتم‌های مختلفی برای حل مسائل داده‌ای استفاده می‌کند. در این پژوهش از سه الگوریتم به روش یادگیری نظارت شده شامل جنگل تصادفی (با دقت بالا و جلوگیری از برازش بیش از حد از طریق ترکیب درخت‌های تصمیم)، درخت تصمیم (با قابلیت تفسیرپذیری بالا و کنترل پیچیدگی) و ماشین بردار پشتیبان (با توانایی مدل‌سازی الگوهای غیرخطی به کمک توابع کرنل) استفاده شده است.

1- Norallahi & Seyed Kaboli

2- Curve Number (CN)

3- Stream Power Index (SPI)


• شاخص‌های ارزیابی

در این پژوهش، به منظور ارزیابی عملکرد مدل‌های پیش‌بینی، معیارهای مختلفی شامل ROC^۱ با تعیین رابطه بین نرخ مثبت واقعی (حساسیت)^۲ و نرخ مثبت کاذب^۳ (ویژگی) در سطوح مختلف آستانه (میرزایی^۴ و همکاران، ۲۰۲۱)، شاخص صحت^۵، امتیاز F1، مساحت زیر منحنی (AUC-ROC)، CV_ROC یا ضریب اعتبارسنجی متقابل AUC، شاخص دقت^۶ و ضریب همبستگی (R) برای بررسی شدت و جهت رابطه خطی بین متغیرها استفاده شد.

• روش انجام پژوهش

در این پژوهش به منظور تهیه نقشه حساسیت‌پذیری زمین لغزش، ابتدا داده‌های مکانی مرتبط با عوامل مؤثر بر وقوع زمین لغزش در منطقه مورد مطالعه جمع‌آوری شدند. این عوامل در سه دسته کلی شامل عوامل توپوگرافی، محیطی، انسانی و عوامل هیدرولوژیکی طبقه‌بندی شدند. سپس با استفاده از اطلاعات تاریخی مربوط به رخداد های زمین لغزش، نقاط وقوع زمین لغزش (نقاط زمین لغزش) و نقاط بدون وقوع زمین لغزش (نقاط عدم زمین لغزش) شناسایی و به عنوان داده‌های هدف مشخص گشتند. برای هر یک از این نقاط، مقادیر مربوط به متغیرهای ورودی با استفاده از ابزار Extract Values to Points در محیط نرم‌افزار ArcMap از نقشه آنان استخراج شده و داده‌ها در قالب جدول سازماندهی شدند. پس از آماده‌سازی داده‌ها، اطلاعات استخراج شده به محیط نرم‌افزار Excel منتقل شدند. در مرحله بعد، داده‌ها به دو بخش آموزش (۷۰ درصد) و اعتبارسنجی (۳۰ درصد) تقسیم شد و مدل‌سازی با بهره‌گیری از الگوریتم‌های یادگیری ماشین در محیط نرم‌افزار R انجام پذیرفت. سپس مدل‌های تولید شده با استفاده از شاخص‌های ارزیابی عملکرد مورد ارزیابی قرار گرفته و در ادامه، مدل برتر بر اساس نتایج ارزیابی انتخاب شد.

در گام نهایی، با بارگذاری لایه‌های رستری متغیرها به محیط R نقشه حساسیت‌پذیری زمین لغزش برای منطقه مورد مطالعه بر اساس مدل برتر و سایر مدل‌ها تولید شد. این نقشه‌ها میزان استعداد یا حساسیت مناطق مختلف به وقوع زمین لغزش را نمایش و می‌تواند به عنوان ابزاری کارآمد در مدیریت مخاطرات محیطی و برنامه‌ریزی مکانی مورد استفاده قرار گیرد. شکل (۳) روند انجام پژوهش را نمایش می‌دهد.



شکل (۳) روند انجام پژوهش

1- Receiver Operating Characteristic (ROC)

2- Sensitivity

3- Specificity

4- Mirzaei

5- Precision

6- Accuracy


یافته‌های پژوهش


• تهیه عوامل موثر بر زمین لغزش

بررسی عوامل تاثیرگذار بر زمین لغزش حوضه پلرود در جدول (۲) و نقشه‌ها در شکل (۴) نشان داده شده است.

جدول (۲) نتایج تهیه شده از عوامل موثر بر زمین لغزش

متغیر	محدوده	ملاحظات
عوامل فیزیوگرافی	ارتفاع (متر)	۳۹۵۰ تا ۳۰-
	شیب (درصد)	۸۹۶/۷۰ تا ۰
	جهت (درجه)	۸ طبقه اصلی و فرعی (۴۵ تا ۳۶۰)
	انحنای زمین	محدب (ارتفاعات)، مقعر (دره‌ها)، مسطح (دشت‌ها)
	TWI	۱/۱۰ تا ۲۵/۱۸
	TRI (متر)	۰ تا ۱۰۸
	TPI	۳۲۲/۹ تا ۱۳۵/۵
عوامل محیطی - انسانی	کاربری اراضی	کشاورزی - پهنه آبی - مسکونی - زمین بایر - جنگل - مراتع
	زمین‌شناسی	سازنده‌های آهک اوریتولینی (K11)، مواد مذاب آتشفشانی دوره دوم (K2v) و گدازه‌های پایه (Pgkv) و ...
	تراکم و فاصله از گسل	متوسط تراکم گسل در حوضه ۲/۲ و حداکثر آن ۳۵/۳۰ کیلومتر بر کیلومتر مربع
	تراکم و فاصله از جاده	طول جاده‌های آسفالت‌ه اصلی حوضه در مجموع ۱۰۰/۲۵ کیلومتر
	NDVI	میانگین مقدار ۰/۲۲
	بارندگی (میلی‌متر)	۹۸۳/۱۴ تا ۱۸۴۲/۲۲
	تراکم و فاصله از آبراهه	با متوسط تراکم آبراهه ۰/۰۴۷
عوامل هیدرولوژیکی	CN	۳۰ تا ۱۰۰
	SPI	مقادیر بالا در بستر آبراهه
		الگوی بارش به شدت تحت تأثیر تغییرات ارتفاعی شبکه آبراهه‌ای حوضه دارای الگوی درختی با کشیدگی بادبزی شکل و زهکش‌ها به سمت خروجی اصلی متمرکز
		طبقات ۵۵، ۶۱ و ۷۰ در سطح حوضه غالب بوده که نشان‌دهنده پتانسیل متوسط تا زیاد تولید رواناب و افزایش استعداد ناپایداری دامنه‌ها
		نشان از ظرفیت بالای فرسایش، زیرسویی و انتقال رسوب






شکل (۴) نقشه‌های عوامل موثر بر زمین لغزش حوضه پلرود

• تهیه نقشه پراکنش نقاط زمین لغزش و عدم زمین لغزش

شکل (۵) نقشه توزیع مکانی نقاط زمین لغزش و عدم زمین لغزش در حوضه پلرود را نشان می‌دهد. همان‌طور که مشاهده می‌شود، پراکنش نقاط وقوع زمین لغزش در سطح حوضه از الگوی نسبتاً متعادلی برخوردار بوده و این رخدادها در تمامی بخش‌ها، از نواحی مرتفع کوهستانی تا مناطق پایین دست حوضه، قابل مشاهده می‌باشد.




شکل (۵) نقشه توزیع مکانی نقاط وقوع زمین لغزش و عدم وقوع زمین لغزش حوضه پلرود

• نتایج همبستگی بین متغیرهای مدل سازی

نتایج تحلیل همبستگی متغیرهای مؤثر بر زمین لغزش نشان داد که برخی عوامل مورفومتری، هیدرولوژیکی و محیطی دارای روابط معنی‌دار با یکدیگر هستند (شکل ۶). شیب و شاخص TRI با ضریب همبستگی ۰/۷۳ رابطه‌ای مثبت و قوی دارند که بیانگر افزایش ناهمواری هم‌زمان با افزایش شیب دامنه‌ها است. همچنین، شاخص TPI و انحنا با ضریب

۰/۸۲ همبستگی مثبت قوی نشان داده و وابستگی ساختاری آن‌ها در توصیف شکل دامنه‌ها را تأیید می‌نماید. بین ارتفاع و فاصله از جاده (۰/۶۹) و نیز ارتفاع و بارندگی (۰/۷۰) همبستگی مثبت نسبتاً قوی مشاهده شد که نقش کنترل‌کننده ارتفاع بر الگوی بارش و توسعه زیرساخت‌ها را نشان می‌دهد. در مقابل، TRI و TPI با ضریب -۰/۸۵ همبستگی منفی قوی داشته و تفاوت کارکرد این دو شاخص در توصیف ناهمواری و موقعیت نسبی توپوگرافی را نشان می‌دهند. همچنین، ارتفاع با NDVI و تراکم جاده به ترتیب با ضرایب ۰/۷۸- و ۰/۶۲- همبستگی منفی قابل‌توجهی دارد که کاهش پوشش گیاهی و تمرکز فعالیت‌های انسانی در ارتفاعات پایین‌تر را منعکس می‌کند. به‌طورکلی، شدت همبستگی‌ها به‌گونه‌ای است که استفاده هم‌زمان از متغیرها در مدل‌سازی حساسیت زمین‌لغزش بدون بروز هم‌خطی شدید امکان‌پذیر می‌باشد.



شکل (۶) نمودار همبستگی بین متغیرهای مدل‌سازی

• نتایج مدل‌سازی با الگوریتم‌ها

مطابق جدول (۳)، بررسی نتایج حاصل از ارزیابی عملکرد مدل‌های مختلف یادگیری ماشین در پیش‌بینی حساسیت زمین‌لغزش نشان می‌دهد که هر یک از الگوریتم‌ها رفتار متفاوتی در شناسایی نواحی مستعد زمین‌لغزش از خود نشان داده‌اند. براین‌اساس، الگوریتم RF با دقت کلی ۰/۶۲ و مقدار AUC برابر با ۰/۷۴ عملکرد قابل‌قبولی در تفکیک نواحی مستعد و غیر مستعد زمین‌لغزش ارائه داده است. اگرچه مقدار حساسیت این مدل نسبتاً پایین (۰/۲۲) بوده، اما ویژگی بالایی (۰/۸۶) آن بیانگر توان مناسب در تشخیص صحیح نواحی پایدار می‌باشد. همچنین مقدار بالای CV-ROC (۰/۹۷) نشان‌دهنده پایداری و قابلیت تعمیم‌پذیری مناسب این مدل است. الگوریتم درخت تصمیم نیز با دستیابی به بیشترین دقت کلی (۰/۶۶) و ویژگی کامل (۱/۰۰)، توانایی بالا در شناسایی صحیح نواحی غیر زمین‌لغزش را از خود نشان داد. با این‌حال، حساسیت بسیار پایین (۰/۱۱) و مقدار AUC برابر با ۰/۵۵ بیانگر ضعف این مدل در شناسایی نواحی مستعد زمین‌لغزش و قدرت تفکیک پایین آن نسبت به سایر الگوریتم‌ها است؛ امری که کاربرد مستقل این مدل را در پهنه‌بندی حساسیت زمین‌لغزش با محدودیت مواجه می‌سازد. در مقابل، الگوریتم SVM با وجود دقت کلی


(۰/۶۲)، مشابه RF بیشترین مقدار حساسیت (۰/۵۵) و امتیاز F1 (۰/۵۲) را به خود اختصاص داد که نشان‌دهنده تعادل مناسب بین تشخیص نواحی مستعد زمین لغزش و غیر مستعد می‌باشد. مقدار AUC این مدل (۰/۶۵) نیز حاکی از توان تفکیک متوسط آن بوده و CV-ROC برابر با ۰/۸۳ پایداری قابل قبول عملکرد مدل را تأیید می‌نماید. در مجموع، نتایج نشان می‌دهد که الگوریتم RF از نظر قدرت تفکیک و پایداری کلی، عملکرد برتری نسبت به سایر مدل‌ها دارد، درحالی‌که SVM در شناسایی نواحی مستعد زمین لغزش حساس‌تر عمل کرده است. ازسوی دیگر، اگرچه درخت تصمیم دقت کلی بالاتری ارائه می‌دهد، اما ضعف آن در تشخیص مناطق مستعد، کارایی آن را در ارزیابی حساسیت زمین لغزش کاهش می‌دهد.

جدول (۳) نتایج ارزیابی عملکرد مدل‌های یادگیری ماشین

مدل‌ها	CV_ROC	AUC	امتیاز F1	صحت	ویژگی	حساسیت	ضریب کاپا	دقت
RF	۰/۹۷	۰/۷۴	۰/۳۰	۰/۵	۰/۸۶	۰/۲۲	۰/۱۰	۰/۶۲
DT	۰/۸۸	۰/۵۵	۰/۲۰	۱	۱	۰/۱۱	۰/۱۳	۰/۶۶
SVM	۰/۸۳	۰/۶۵	۰/۵۲	۰/۵	۰/۶۶	۰/۵۵	۰/۲۱	۰/۶۲

• متغیرهای مؤثر در مدل‌سازی حساسیت به زمین لغزش


نتایج تحلیل اهمیت متغیرها در مدل‌های مختلف یادگیری ماشین نشان‌دهنده تفاوت معنادار در نقش عوامل مؤثر بر حساسیت زمین لغزش در حوضه پلرود است (شکل ۷). در مدل جنگل تصادفی، شاخص TRI با اهمیت نسبی ۱۰۰ درصد به عنوان مؤثرترین عامل شناسایی شد. پس از آن، شاخص TPI با حدود ۷۵ درصد اهمیت در رتبه دوم، شاخص SPI و شماره منحنی با اهمیت در حدود ۴۴ درصد، در جایگاه‌های بعدی اثرگذاری قرار داشتند. این الگو نشان می‌دهد که ترکیب عوامل مورفومتری و هیدرولوژیکی در عملکرد بالای مدل RF نقش کلیدی ایفا کرده است. درخت تصمیم نیز شاخص TRI با اهمیت ۱۰۰ درصد، بیشترین تأثیر را در فرایند تصمیم‌گیری مدل داشته است. پس از آن، شماره منحنی با حدود ۵۴ درصد، بارش با نزدیک به ۴۳ درصد و شاخص TPI با حدود ۴۱ درصد اهمیت، به عنوان عوامل مؤثر بعدی شناسایی شدند. ساختار این مدل نشان می‌دهد که DT عمدتاً بر متغیرهای تمرکز کرده است که بیشترین قدرت تفکیک را در داده‌ها داشته‌اند و سایر عوامل نقش معناداری در بهبود عملکرد مدل ایفا نکرده‌اند. در مقابل، الگوی اهمیت متغیرها در مدل SVM متفاوت می‌باشد؛ به گونه‌ای که شماره منحنی با اهمیت ۱۰۰ درصد، مؤثرترین متغیر در تفکیک نواحی مستعد و غیر مستعد شناخته شد. شاخص TPI با حدود ۷۳ درصد اهمیت در رتبه دوم قرار گرفت و متغیرهای NDVI و ارتفاع، هر یک با حدود ۶۷ درصد اهمیت، نقش قابل توجهی در عملکرد مدل داشتند. همچنین متغیرهای فاصله از آبراهه، فاصله از جاده و بارش در رتبه‌های بعدی اهمیت قرار گرفتند که بیانگر حساسیت مدل SVM به ترکیبی از عوامل هیدرولوژیکی، توپوگرافی و انسانی است.




شکل (۷) نمودار اهمیت متغیرهای مؤثر در مدل‌سازی با الگوریتم‌ها

• نقشه مناطق مستعد زمین‌لغزش بر اساس مدل‌ها


شکل‌های (۸ الی ۱۱) نقشه نتایج پهنه‌بندی حساسیت زمین‌لغزش را نشان می‌دهد. مدل جنگل تصادفی (RF)، به‌عنوان مدل برتر بر اساس شاخص‌های ارزیابی، الگوی مکانی متعادل‌تری از توزیع کلاس‌های حساسیت ارائه داده است (شکل ۸). مطابق نتایج این مدل، حدود ۷۶/۳۷ درصد از مساحت کل حوزه پلرود، معادل ۱۳۱.۲۱۳/۵ هکتار، در طبقه با حساسیت کم و حدود ۲۴ درصد، معادل ۴۰۵.۷۹/۰۸ هکتار، در طبقه با حساسیت زیاد قرار گرفته است. این توزیع بیانگر توانایی بالای مدل RF در تفکیک منطقی نواحی پایدار و ناپایدار و کاهش عدم قطعیت در پهنه‌بندی حساسیت زمین‌لغزش است. در ادامه، نتایج مدل ماشین بردار پشتیبان (SVM) نشان داد که بخش عمده‌ای از حوزه در طبقه با حساسیت کم قرار گرفته است (شکل ۹)؛ به‌طوری که حدود ۹۴/۷۴ درصد از مساحت کل، معادل ۱۶۲.۷۶۹/۵۸ هکتار، به‌عنوان پهنه کم‌خطر شناسایی شد، درحالی که تنها ۵/۲۵ درصد از مساحت، معادل ۹۰۳.۱/۲۰ هکتار، در طبقه با حساسیت زیاد قرار گرفت. این الگو حاکی از رویکرد محافظه‌کارانه‌تر مدل SVM در شناسایی مناطق مستعد لغزش است. در مقابل، مدل درخت تصمیم (DT) توزیعی متفاوت و نسبتاً متوازن میان طبقات حساسیت ارائه کرد (شکل ۱۰)؛ به‌گونه‌ای که حدود ۴۸ درصد از مساحت حوزه (۸۳.۰۳۷/۳۵ هکتار) در طبقه با حساسیت کم و حدود ۵۲ درصد (۸۸.۷۵۸/۳۱ هکتار) در طبقه با حساسیت زیاد طبقه‌بندی شد. این نتایج نشان می‌دهد که مدل DT تمایل بیشتری به شناسایی گسترده نواحی با حساسیت بالا داشته و نسبت به تغییرات متغیرهای ورودی واکنش شدیدتری از خود نشان داده است. همچنین مطابق شکل (۱۱)، نواحی مشترک با حساسیت زیاد زمین‌لغزش قابل‌مشاهده است که در آن هر سه مدل، بر اساس شاخص‌های ارزیابی، هم‌پوشانی بالایی دارند. این مناطق مشترک حدود ۵۵۷۷/۶۱۹ هکتار از کل پهنه‌های با حساسیت بالای شناسایی‌شده توسط تمامی مدل‌ها را در بر می‌گیرد.




شکل (۹) نقشه پیش‌بینی مناطق مستعد زمین‌لغزش
توسط مدل SVM



شکل (۸) نقشه پیش‌بینی مناطق مستعد زمین‌لغزش
توسط مدل برتر (RF)



شکل (۱۱) نقشه پیش‌بینی مناطق مشترک مستعد
زمین‌لغزش توسط مدل‌ها



شکل (۱۰) نقشه پیش‌بینی مناطق مستعد زمین‌لغزش
توسط مدل DT

بحث و نتیجه‌گیری

در این پژوهش، نقشه حساسیت زمین‌لغزش در حوزه آبخیز پلرود با استفاده از ارزیابی تطبیقی سه الگوریتم یادگیری ماشین شامل جنگل تصادفی (RF)، درخت تصمیم (DT) و ماشین بردار پشتیبان (SVM) تهیه شد. برای مدل‌سازی، ۱۹ متغیر مؤثر در سه گروه اصلی عوامل توپوگرافی، محیطی - انسانی و هیدرولوژیکی مورداستفاده قرار گرفت. نتایج ارزیابی عملکرد مدل‌ها نشان داد که مدل RF با ارائه توزیع متعادل‌تر کلاس‌های حساسیت و دقت بالاتر، حدود ۲۴ درصد از مساحت حوضه را به‌عنوان مناطق با حساسیت زیاد به زمین‌لغزش شناسایی کرد و در مقایسه با سایر مدل‌ها، الگوی واقع‌بینانه‌تری از پهنه‌های مستعد لغزش ارائه داد. در مقابل، سهم مناطق با حساسیت زیاد در مدل SVM به طور محسوسی کمتر (حدود ۵/۲۵ درصد) بوده و مدل درخت تصمیم به‌مراتب تمایل بیشتر به‌پیش‌برآورد مناطق پرخطر از خود نشان داد که نشان‌دهنده گرایش متفاوت این الگوریتم‌ها در برآورد سطح خطر می‌باشد. اگرچه الگوی مکانی پهنه‌های پرخطر در مدل‌های RF و SVM هم‌پوشانی قابل‌توجهی دارد، اما مدل SVM به‌ویژه در بخش‌های

میانی حوزه تمایل بیشتری به طبقه‌بندی مناطق در کلاس حساسیت کم نشان داد. این تفاوت را می‌توان به ماهیت الگوریتم‌ها نسبت داد. از سوی دیگر، مدل درخت تصمیم با واکنش شدیدتر نسبت به تغییرات متغیرهای ورودی، گستره وسیع‌تری از مناطق را در کلاس حساسیت زیاد قرار داده است که اگرچه می‌تواند در شناسایی نواحی پرخطر مفید باشد، اما احتمال بیش‌برآورد خطر را نیز افزایش می‌دهد. تحلیل اهمیت متغیرها نشان داد که شاخص‌های مورفومتری، به‌ویژه شاخص‌های TRI و TPI، در تمامی مدل‌ها از بیشترین اهمیت برخوردارند که بیانگر نقش تعیین‌کننده ساختار توپوگرافی در کنترل پایداری دامنه‌ها در حوزه پلرود است. تغییرات شدید ارتفاعی، ناهمگنی هندسی دامنه‌ها و پیچیدگی توپوگرافی، زمینه‌ساز تمرکز تنش‌های برشی و افزایش استعداد زمین‌لغزش در این منطقه می‌باشند. هم‌زمان، اهمیت بالای متغیرهای هیدرولوژیکی نظیر شماره منحنی و شاخص SPI نشان می‌دهد که فرایندهای مرتبط با تولید رواناب، تمرکز جریان و فرسایش کناری، نقش مؤثری در تحریک و تشدید رخداد‌های زمین‌لغزش ایفا می‌نماید. این نتایج با یافته‌های ساداتی و همکاران (۱۴۰۴) و یو و همکاران (۲۰۲۳) هم‌راستا بوده و بر نقش کلیدی ناهمگنی توپوگرافی و فرایندهای هیدرولوژیکی در ناپایداری دامنه‌های کوهستانی تأکید دارد. یافته‌های این پژوهش که برتری الگوریتم جنگل تصادفی را در پهنه‌بندی حساسیت زمین‌لغزش نشان می‌دهد، با بخش قابل‌توجهی از مطالعات پیشین همخوانی دارد. پژوهش‌های انجام‌شده توسط عرب عامری و همکاران (۲۰۲۰)؛ چوئی و همکاران (۲۰۲۴)؛ آبدو و ریچی (۲۰۲۴)؛ شهابی و همکاران (۲۰۲۳) نیز گزارش کردند که مدل RF در مقایسه با الگوریتم‌هایی نظیر SVM، DT، ADTree^۱، FLDA^۲، XGBoost^۳، CNN^۴ و LR^۵ دقت بالاتر و توان بیشتری در بازنمایی الگوی مکانی زمین‌لغزش ارائه می‌دهد. مقادیر بالای AUC گزارش‌شده در این مطالعات، مشابه نتایج پژوهش حاضر، بیانگر قابلیت بالای RF در مدل‌سازی روابط غیرخطی و پیچیده میان عوامل مؤثر و کاهش اثر بیش‌برازش است. در مقابل، برخی پژوهش‌های داخلی از جمله دسترنج و همکاران (۱۴۰۱)، نظریانی و فلاح (۱۴۰۲) و باباربع و همکاران (۱۴۰۴) و سهین^۶ و همکاران (۲۰۲۰)، عملکرد بهتری را برای الگوریتم‌هایی نظیر LR، SVM، ANN^۷، بیشینه آنتروپی^۸ و الگوریتم‌های یادگیری جمعی^۹ گزارش کرده‌اند. این اختلاف نتایج می‌تواند ناشی از تفاوت در ماهیت داده‌های آموزشی، تعداد و توزیع رخداد‌های زمین‌لغزش، ساختار زمین‌شناسی مناطق مورد مطالعه و انتخاب الگوریتم‌ها باشد. برخلاف برخی پژوهش‌ها با تأکید بر عوامل انسانی، در حوزه پلرود عوامل مورفومتری و هیدرولوژیکی نقش غالب دارند. همچنین پهنه‌های مستعد شناسایی شده توسط مدل جنگل تصادفی، مبنای مناسبی برای اولویت‌بندی اقدامات کاهش خطر، برنامه‌ریزی کاربری اراضی و مدیریت بحران در این حوزه آبخیز فراهم می‌آورد.

با وجود نتایج قابل‌قبول حاصل از این پژوهش، برخی محدودیت‌ها نیز باید مدنظر قرار گیرد. از جمله محدودیت‌های اساسی این پژوهش، کمبود نقاط ثبت‌شده زمین‌لغزش و نبود یک بانک اطلاعاتی جامع و مستند از رخداد‌های زمین‌لغزش در حوزه آبخیز پلرود است که موجب عدم توازن ذاتی میان داده‌های زمین‌لغزش و نواحی پایدار گردید. این عدم توازن داده‌ای که از چالش‌های رایج در مطالعات پهنه‌بندی حساسیت زمین‌لغزش محسوب می‌شود، می‌تواند بر عملکرد برخی شاخص‌های ارزیابی و توان تفکیک مدل‌ها در شناسایی رخداد‌های واقعی زمین‌لغزش تأثیرگذار باشد. افزون بر این، بخشی از نقاط ثبت‌شده زمین‌لغزش از دقت مکانی کافی برخوردار نبوده و به دلیل

1- Alternative Decision Tree (ADTree)

2- Fisher's Linear Discriminant Function (FLDA)

3- Extreme Gradient Boost (XGBoost)

4- Convolutional Neural Network (CNN)

5- Logistic Regression (LR)

6- Sahin

7- Artificial Neural Network (ANN)

8- Maximum entropy

9- Ensemble learning methods

محدودیت در دسترسی به تصاویر ماهواره‌ای با قدرت تفکیک مناسب در بازه زمانی رخداد، امکان بازبینی و اصلاح دقیق موقعیت این نقاط فراهم نشد که می‌تواند منجر به بروز عدم قطعیت در فرایند آموزش و اعتبارسنجی مدل‌ها شود. از سوی دیگر، به دلیل فقدان مطالعات پیشین در مقیاس حوضه پلرود، امکان مقایسه مستقیم نتایج حاصل از این پژوهش با مطالعات مشابه منطقه‌ای یا بهره‌گیری از تجربیات پیشین در این حوضه میسر نبود.

با وجود این محدودیت‌ها، نتایج حاصل به‌روشنی نشان می‌دهد که به‌کارگیری الگوریتم‌های یادگیری ماشین، به‌ویژه جنگل تصادفی، توان بالایی در شناسایی الگوی مکانی ناپایداری دامنه‌ها و پهنه‌بندی حساسیت زمین‌لغزش در حوضه پلرود دارد. برتری مدل جنگل تصادفی در مقایسه با ماشین بردار پشتیبان و درخت تصمیم، عمدتاً ناشی از ساختار تجمعی، توانایی مدل‌سازی روابط غیرخطی و کاهش اثر نویز داده‌ها بوده و منجر به ارائه نقشه‌هایی با پایداری و واقع‌بینی بیشتر شده است. از این‌رو، نقشه‌های حساسیت حاصل از این مدل می‌توانند به‌عنوان ابزاری کارآمد در پشتیبانی از تصمیم‌گیری‌های مدیریتی، برنامه‌ریزی کاربری اراضی و کاهش ریسک مخاطرات ژئومورفولوژیکی مورد استفاده قرار گیرند؛ به‌ویژه در حوضه‌هایی که با محدودیت داده‌های تاریخی و پیچیدگی بالای شرایط توپوگرافی و هیدرولوژیکی مواجه‌اند. در نهایت، هرچند تعمیم نتایج به سایر مناطق مستلزم احتیاط و توجه به مقیاس و کیفیت داده‌هاست، پژوهش حاضر نشان می‌دهد که الگوریتم جنگل تصادفی رویکردی کارآمد و آینده‌دار برای تحلیل و مدیریت مخاطره زمین‌لغزش در حوضه‌های کوهستانی محسوب می‌شود.

به‌منظور دستیابی به راهکارهای مؤثر و پایدار در مدیریت خطر زمین‌لغزش، پیشنهاد می‌شود رویکردهای زیر در تحقیقات آتی و اقدامات اجرایی مدنظر قرار گیرند:

توسعه و پایش مستمر مدل‌های پیش‌بینی: با بهره‌گیری از دستاوردهای این مطالعه در به‌کارگیری مدل‌های یادگیری ماشین، لازم است برنامه‌هایی جامع برای پایش مستمر مناطق در معرض خطر تدوین شود. این پایش‌ها باید با ترکیب داده‌های میدانی، سنجش‌ازدور با وضوح بالا (مانند تصاویر ماهواره‌ای)، و به‌روزرسانی دوره‌ای مدل‌ها، دقت پیش‌بینی‌ها را افزایش داده و امکان شناسایی زودهنگام مخاطرات را فراهم آورد.

اجرای راهکارهای مهندسی و حفاظتی هدفمند: نتایج حاصل از ارزیابی خطر باید مبنایی برای طراحی و اجرای پروژه‌های مهندسی حفاظتی در نقاط پرخطر شناسایی‌شده قرار گیرد. این پروژه‌ها می‌توانند شامل احداث سیستم‌های زهکشی بیشتر، اجرای روش‌های تثبیت شیب با مصالح بومی و پایدار یا توسعه دیوارهای حائل باشند. ارزیابی اثربخشی این راهکارها در شرایط واقعی منطقه نیز ضروری است.

تقویت همکاری‌های میان‌بخشی و مشارکت اجتماعی: مدیریت مؤثر زمین‌لغزش نیازمند یکپارچه‌سازی تلاش‌های نهادهای مسئول است. علاوه بر این، ایجاد سازوکارهایی برای آموزش، اطلاع‌رسانی و مشارکت فعال جامعه محلی در فرایندهای پایش و گزارش‌دهی، نقشی حیاتی در موفقیت بلندمدت برنامه‌های پیشگیرانه خواهد داشت.

اجرای این پیشنهادها، گامی مهم در جهت ارتقای تاب‌آوری جوامع در برابر مخاطرات زمین‌لغزش و تضمین توسعه پایدار در مناطق آسیب‌پذیر خواهد بود.

منابع

- بابابی، نگار، لرستانی، قاسم، و اسماعیلی، رضا (۱۴۰۴). پهنه‌بندی وقوع خطر زمین‌لغزش با استفاده از مدل‌های جنگل تصادفی و ماشین بردار. *پژوهش‌های دانش زمین*، ۱۶(۱)، ۱۵۲-۱۶۸. doi:org/10.48308/esrj.2025.236839.1234
- بابلی مؤخر، حمید، تقیان، علی رضا، و شیرانی، کورش (۱۳۹۷). ارزیابی نقشه پهنه‌بندی حساسیت زمین‌لغزش با استفاده از روش تلفیقی فاکتور اطمینان و رگرسیون لجستیک با به‌کارگیری شاخص‌های ژئومورفومتریک. *پژوهش‌های ژئومورفولوژی کمی*، ۷(۳)، ۹۱-۱۱۶. dor:isc.ac/dor/20.1001.1.22519424.1397.7.3.6.4

- حجازی، سید اسدالله (۱۳۹۳). پهنه‌بندی خطر زمین‌لغزش در حوضه گویچه بل اهر با استفاده از سیستم اطلاعات جغرافیایی (GIS). *جغرافیا و برنامه‌ریزی*، ۱۸ (۵۰)، ۱۳۵-۱۵۲.
- دسترنج، علی، و کریمی سنگچینی، ابراهیم (۱۴۰۱). پیش‌بینی حساسیت وقوع زمین‌لغزش با الگوریتم یادگیری ماشین بیشینه آنتروپی (حوزه آبخیز بار نیشابور). *پژوهش‌های دانش زمین*، ۱۳ (۵۱)، ۷۶-۹۶. doi:org/10.48308/esrj.2022.102965
- دسترنج، علی، کریمی سنگچینی، ابراهیم، و نور، حمزه (۱۴۰۳). ارزیابی ریسک زمین‌لغزش در حوزه آبخیز بار نیشابور، استان خراسان رضوی. *علوم و مهندسی آبخیزداری ایران*، ۱۸ (۶۷)، ۴۷۰-۴۷۴. doi:org/10.22034/18.67.4
- ساداتی، سید حمید، موسوی، سید رمضان، وهاب‌زاده کبریا، قربان، و روشن، سید حسن. (۱۴۰۴). ارزیابی مدل‌های جنگل تصادفی و ماشین بردار پشتیبان در نقشه‌برداری خطر زمین‌لغزش (مطالعه موردی: حوضه تجن، استان مازندران). *مجله مخاطرات طبیعی محیطی*، ۱۴ (۴۵)، ۱۳۳-۱۵۴. doi:org/10.22111/jneh.2025.50031.2071
- طالبی، علی، نفرزادگان، علیرضا، و ملکی نژاد، حسین (۱۳۸۸). مروری بر مدل‌سازی تجربی و فیزیکی زمین‌لغزش‌های ناشی از بارندگی. *پژوهش‌های جغرافیای طبیعی (پژوهش‌های جغرافیایی)*، ۴۱ (۷۰)، ۴۵-۶۴.
- فیض‌نیا، سادات، حسن‌زاده، محمد، و احمدی، حسن (۱۳۸۰). پهنه‌بندی خطر زمین‌لغزش حوزه آبخیز شلمان رود در استان گیلان. *منابع طبیعی ایران*، ۵۴ (۳)، ۲۰۷-۲۲۰.
- مددی، عقیل، پیروزی، الناز، و فعال‌نذیری، مهدی (۱۳۹۹). ارزیابی مقایسه‌ای الگوریتم‌های تصمیم‌گیری چندمعیاره MABAC و CODAS در پهنه‌بندی خطر زمین‌لغزش، نمونه پژوهش: شهرستان کوثر. *جغرافیا و برنامه‌ریزی محیطی*، ۳۱ (۴)، ۱-۲۴. doi:org/10.22108/gep.2020.124723.1348
- نظریانی، نسترن، و فلاح، اصغر (۱۴۰۲). مدل‌سازی خطر وقوع زمین‌لغزش با استفاده از داده‌کاوی در جنگل‌های هیرکانی. *پژوهش‌نامه مدیریت حوزه آبخیز*، ۱۴ (۲۷)، ۱۲۳-۱۳۴. doi:org/2010.61186/jwmr.14.27.123
- Abdo, H. G., & Richi, S. M. (2024). Application of machine learning in the assessment of landslide susceptibility: A case study of mountainous eastern Mediterranean region, Syria. *Journal of King Saud University-Science*, 36(5), 103174. doi:org/10.1016/j.jksus.2024.103174.
- Akbar, T. A., & Ha, S. R. (2011). Landslide hazard zoning along Himalayan Kaghan Valley of Pakistan—by integration of GPS, GIS, and remote sensing technology. *Landslides*, 8(4), 527–540. doi:org/10.1007/s10346-011-0260-1.
- Allegri, E., Zanetti, M., Torresan, S., & Critto, A. (2024). Pluvial flood risk assessment for 2021–2050 under climate change scenarios in the Metropolitan City of Venice. *Science of the Total Environment*, 914, 169925. doi:org/10.1016/j.scitotenv.2024.169925.
- Arabameri, A., Saha, S., Roy, J., Chen, W., Blaschke, T., & Tien Bui, D. (2020). Landslide susceptibility evaluation and management using different machine learning methods in the Gallicash River Watershed, Iran. *Remote Sensing*, 12(3), 475. doi:org/10.3390/rs12030475.
- Cui, J., Kou, P., Tao, Y., Jin, Z., Huang, Y., & Zhang, J. (2024). Enhanced Landslide Susceptibility Mapping Using Machine Learning and InSAR Integration: A Case Study in Wushan County, Three Gorges Reservoir Area, China. doi:org/10.21203/rs.3.rs-4766128/v1.
- Fatemi Aghda, S. M., Bagheri, V., & Razifard, M. (2018). Landslide susceptibility mapping using fuzzy logic system and its influences on mainlines in lashgarak region, Tehran, Iran. *Geotechnical and Geological Engineering*, 36(2), 915–937. doi:org/10.1007/s10706-017-0365-y.
- Haftlang, K. K., & Lang, K. K. H. (2003). *The book of Iran: a survey of the geography of Iran*. Alhoda UK.
- Kühnl, M., Sapena, M., Wurm, M., Geiß, C., & Taubenböck, H. (2023). Multitemporal landslide exposure and vulnerability assessment in Medellín, Colombia. *Natural Hazards*, 119(2), 883–906. doi:org/10.1007/s11069-022-05679-z.
- Lin, L., Lin, Q., & Wang, Y. (2017). Landslide susceptibility mapping on a global scale using the method of logistic regression. *Natural Hazards and Earth System Sciences*, 17(8), 1411–1424. doi:org/10.5194/nhess-17-1411-2017.
- Meles, M. B., Younger, S. E., Jackson, C. R., Du, E., & Drover, D. (2020). Wetness index based on landscape position and topography (WILT): Modifying TWI to reflect landscape position. *Journal of Environmental Management*, 255, 109863. doi:org/10.1016/j.jenvman.2019.109863.
- Mirzaei, S., Vafakhah, M., Pradhan, B., & Alavi, S. J. (2021). Flood susceptibility assessment using

- extreme gradient boosting (EGB), Iran. *Earth Science Informatics*, 14(1), 51–67. doi:org/10.1007/s12145-020-00530-0.
- Mojaddadi, H., Pradhan, B., Nampak, H., Ahmad, N., & Ghazali, A. H. bin. (2017). Ensemble machine-learning-based geospatial approach for flood risk assessment using multi-sensor remote-sensing data and GIS. *Geomatics, Natural Hazards and Risk*, 8(2), 1080–1102. doi:org/10.1080/19475705.2017.1294113.
- Norollahi, M., & Seyed Kaboli, H. (2021). Urban flood hazard mapping using machine learning models: GARP, RF, MaxEnt and NB. *Natural Hazards*, 106, 119–137. doi:org/10.1007/s11069-020-04453-3.
- Pandey, A., Dabral, P. P., Chowdary, V. M., & Yadav, N. K. (2008). Landslide hazard zonation using remote sensing and GIS: a case study of Dikrong river basin, Arunachal Pradesh, India. *Environmental Geology*, 54(7), 1517–1529. doi:org/10.1007/s00254-007-0933-1.
- Patel, M., Chavda, M., Patel, R., Goswami, A., & Mevada, J. (2024). Predicting Landslide Using Machine Learning Techniques. *ITM Web of Conferences*, 65, 3012. doi:org/10.1051/itmconf/20246503012.
- Pradhan, B. (2011). Use of GIS-based fuzzy logic relations and its cross application to produce landslide susceptibility maps in three test areas in Malaysia. *Environmental Earth Sciences*, 63(2), 329–349. doi:org/10.1007/s12665-010-0705-1.
- Sahin, E. K., Colkesen, I., & Kavzoglu, T. (2020). A comparative assessment of canonical correlation forest, random forest, rotation forest and logistic regression methods for landslide susceptibility mapping. *Geocarto International*, 35(4), 341–363. doi:org/10.1080/10106049.2018.1516248.
- SELLAMI, E. M., & Rhinane, H. (2024). Google Earth Engine and Machine Learning for Flash Flood Exposure Mapping—Case Study: Tetouan, Morocco. *Geosciences (Switzerland)*, 14(6). doi:org/10.3390/geosciences14060152.
- Shahabi, H., Ahmadi, R., Alizadeh, M., Hashim, M., Al-Ansari, N., Shirzadi, A., Wolf, I. D., & Ariffin, E. H. (2023). Landslide susceptibility mapping in a mountainous area using machine learning algorithms. *Remote Sensing*, 15(12), 3112. doi:org/10.3390/rs15123112.
- Towfiqul Islam, A. R. M., Talukdar, S., Mahato, S., Kundu, S., Eibek, K. U., Pham, Q. B., Kuriqi, A., & Linh, N. T. T. (2021). Flood susceptibility modelling using advanced ensemble machine learning models. *Geoscience Frontiers*, 12(3). doi:org/10.1016/j.gsf.2020.09.006
- Wang, Y., Fang, Z., & Hong, H. (2019). Comparison of convolutional neural networks for landslide susceptibility mapping in Yanshan County, China. *Science of the Total Environment*, 666, 975–993. doi:org/10.1016/j.scitotenv.2019.02.263.
- Yu, H., Pei, W., Zhang, J., & Chen, G. (2023). Landslide susceptibility mapping and driving mechanisms in a vulnerable region based on multiple machine learning models. *Remote Sensing*, 15(7), 1886. doi:org/10.3390/rs15071886.
- Zare, M., Pourghasemi, H. R., Vafakhah, M., & Pradhan, B. (2013). Landslide susceptibility mapping at Vaz Watershed (Iran) using an artificial neural network model: a comparison between multilayer perceptron (MLP) and radial basic function (RBF) algorithms. *Arabian Journal of Geosciences*, 6(8), 2873–2888. doi:org/10.1007/s12517-012-0610-x
- Zhuo, L., Huang, Y., Zheng, J., Cao, J., & Guo, D. (2023). Landslide susceptibility mapping in Guangdong Province, China, using random forest model and considering sample type and balance. *Sustainability*, 15(11), 9024. doi:org/10.3390/su15119024.