

## Evaluation and comparison of machine learning and deep learning models in landslide susceptibility zoning case study: forest watershed 85, Golestan Province

Shadi Jalilian<sup>1</sup>, Shaban Shataee Jouibary<sup>2\*</sup>, Mohammad Hadi Meirani<sup>3</sup> and Amir Saadoddin<sup>4</sup>

<sup>1</sup> Ph.D. Student, Department of Forestry, Faculty of Forest Sciences, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

<sup>2\*</sup> Professor, Department of Forestry, Faculty of Forest Sciences, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

<sup>3</sup> Professor, Department of Forestry, Faculty of Forest Sciences, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

<sup>4</sup> Professor, Department of Watershed Management, Faculty of Rangeland and Watershed Management, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

Received: 11 July 2025

Accepted: 11 November 2025

### Extended abstract

#### Introduction

Landslides, as one of the most destructive natural disasters, cause significant annual human and financial losses worldwide, particularly in Golestan Province due to its specific topographic and climatic conditions. Although numerous studies have been conducted in this region, most have relied on classical and traditional statistical methods, leaving a notable gap in the application of advanced deep learning algorithms. This research aimed to address this gap with three main innovations: 1) employing deep learning models (CNN and RNN) for the first time in the region, 2) conducting a systematic comparison with classical machine learning models (RF and SVM), and 3) focusing on a forest watershed with a sensitive and complex ecosystem (Hyrcanian).

#### Materials and methods

The study area was Forest Watershed 85, covering approximately 39,288 hectares in Golestan Province. Based on previous studies and analysis of regional conditions, ten factors influencing landslide occurrence were selected: elevation, slope percentage, slope aspect, Topographic Wetness Index (TWI), Normalized Difference Vegetation Index (NDVI), land use, distance to roads, distance to rivers, distance to faults, and average annual rainfall. These factors were prepared as raster layers with a 30x30 meter cell size in a Geographic Information System (ArcGIS) environment. Landslide point data (247 points) were obtained from the General Department of Natural Resources and Watershed Management of Golestan Province. To balance the dataset, an equal number of points (247) were randomly selected from areas without landslide phenomena. Thus, a balanced dataset comprising 494 points was prepared for modeling. The data were split into a 70:30 ratio (346 points for training and 148 points for validation). Four advanced models, including two machine learning models (Random Forest, RF, and Support Vector Machine, SVM) and two deep learning models (Convolutional Neural Network, CNN, and Recurrent Neural Network, RNN), were implemented and trained in the Python environment using the Scikit-learn and TensorFlow libraries. The performance of the models was quantitatively evaluated using the Receiver Operating Characteristic (ROC) curve and the Area Under the Curve (AUC) index. Furthermore, the validation of the generated susceptibility maps in high-risk areas (high and very high-risk classes) was performed using 30% of the unused samples, assessed by the overall accuracy and Kappa coefficient metrics.

#### Results and discussion

In this research, the performance of four machine learning and deep learning algorithms was evaluated for landslide susceptibility zoning in Forest Watershed 85 of Golestan Province. The results demonstrated that the deep learning algorithm CNN, with an AUC score of 0.910, an overall accuracy of 87.72%, and a Kappa coefficient of 0.899 for high-risk classes (high and very high risk), was identified as the most efficient model. Variable importance analysis using the superior model (CNN) revealed that the factors

\* Corresponding author: shataee@gau.ac.ir

Distance to Fault and Distance to River were respectively the most significant contributors to landslide occurrence in the study area. This finding is entirely consistent with the geological and geomorphological expectations of the region. The final landslide susceptibility map generated by the CNN model indicated that 31.46% of the watershed area (approximately equivalent to 12,360 hectares) is classified within the very high-risk category.

### Conclusion

The findings of this research clearly confirm the superiority and high potential of deep learning algorithms, particularly the Convolutional Neural Network (CNN) architecture, for producing high-accuracy landslide susceptibility maps compared to machine learning algorithms. The generated map can serve as a reliable and powerful scientific tool for managers and planners, enabling them to prioritize preventive measures, risk management, and safe land-use planning by focusing on high-risk areas. For future studies, integrating these models with optimization algorithms, utilizing higher-resolution data to overcome the limitations of the current data, and developing hybrid frameworks that enhance both accuracy and interpretability are recommended.

**Keywords:** Convolutional Neural Network (CNN), Hyrcanian forests, Landslide susceptibility prediction, Receiver Operating Characteristic (ROC) curve, Spatial modeling,

Cite this article: Jalilian, Sh., Shataee Jouibary, Sh., Meirani, M.H., Saadoddin, A., 2026. Evaluation and comparison of machine learning and deep learning models in landslide susceptibility zoning, case study: forest watershed 85, Golestan Province. *Watershed. Water. Eng. Manag.* 18(1), 45-63.

© 2026, The Author(s). Published by Soil Conservation and Watershed Management Research Institute (SCWMRI). This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>)



## ارزیابی و مقایسه مدل‌های یادگیری ماشین و یادگیری عمیق در پهنه‌بندی حساسیت زمین‌لغزش، مطالعه موردی: حوزه آبخیز جنگلی ۸۵ استان گلستان

شادی جلیلیان<sup>۱</sup>، شعبان شتابی جویباری<sup>۲\*</sup>، محمدهادی معیری<sup>۳</sup> و امیر سعدالدین<sup>۴</sup>

<sup>۱</sup> دانشجوی دکتری، گروه جنگلداری، دانشکده علوم جنگل، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران

<sup>۲</sup> استاد، گروه جنگلداری، دانشکده علوم جنگل، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران

<sup>۳</sup> استاد، گروه جنگلداری، دانشکده علوم جنگل، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران

<sup>۴</sup> استاد، گروه آبخیزداری، دانشکده مرتع و آبخیزداری، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران

تاریخ پذیرش: ۱۴۰۴/۰۸/۲۰

تاریخ دریافت: ۱۴۰۴/۰۴/۲۰

### چکیده مبسوط

#### مقدمه

زمین‌لغزش به‌عنوان یکی از مخرب‌ترین بلایای طبیعی، سالانه خسارات جانی و مالی قابل توجهی در سراسر جهان و به‌ویژه در استان گلستان به‌دلیل شرایط خاص توپوگرافیکی و اقلیمی به بار می‌آورد. اگرچه مطالعات متعددی در این منطقه انجام شده، اما عمده آنها بر روش‌های کلاسیک و آماری سنتی تکیه داشته و خلأ استفاده از الگوریتم‌های پیشرفته یادگیری عمیق به‌شدت احساس می‌شود. این پژوهش با هدف پرکردن این خلأ و با سه نوآوری اصلی (۱) استفاده از مدل‌های یادگیری عمیق (CNN و RNN) برای اولین بار در منطقه، (۲) انجام مقایسه سیستماتیک با مدل‌های کلاسیک یادگیری ماشین (RF و SVM) و (۳) تمرکز بر یک حوزه آبخیز جنگلی با اکوسیستم حساس و پیچیده (هیرکانی) انجام شد.

#### مواد و روش‌ها

منطقه مورد مطالعه، حوزه آبخیز جنگلی ۸۵ به مساحت تقریبی ۳۹۲۸۸ هکتار در استان گلستان بود. بر اساس مطالعات پیشین و تحلیل شرایط منطقه، ده عامل مؤثر بر وقوع زمین‌لغزش شامل ارتفاع، درصد شیب، جهت شیب، شاخص رطوبت توپوگرافی (TWI)، شاخص تفاضل نرمال شده پوشش گیاهی (NDVI)، کاربری اراضی، فاصله از جاده، فاصله از رودخانه، فاصله از گسل و میانگین بارندگی سالانه انتخاب و در محیط سامانه اطلاعات جغرافیایی (ArcGIS) به‌صورت لایه‌های رستری با اندازه سلول ۳۰×۳۰ متر تهیه شدند. داده‌های نقطه‌ای زمین‌لغزش (۲۴۷ نقطه) از اداره کل منابع طبیعی و آبخیزداری استان گلستان اخذ و به‌منظور ایجاد تعادل در مجموعه داده، به همان تعداد (۲۴۷ نقطه) نیز به‌صورت تصادفی از مناطقی که فاقد پدیده زمین‌لغزش بودند، انتخاب شدند. بدین ترتیب، یک مجموعه داده متعادل متشکل از ۴۹۴ نقطه برای مدل‌سازی آماده شد. این داده‌ها با نسبت ۷۰ به ۳۰ (۳۴۶ نقطه برای آموزش و ۱۴۸ نقطه برای اعتبارسنجی) تقسیم شدند.

چهار مدل پیشرفته شامل دو مدل یادگیری ماشین (جنگل تصادفی RF و ماشین بردار پشتیبان SVM) و دو مدل یادگیری عمیق (شبکه عصبی پیچشی CNN و شبکه عصبی بازگشتی RNN) در محیط پایتون و با استفاده از کتابخانه‌های Scikit-learn و TensorFlow پیاده‌سازی و آموزش داده شدند. میزان عملکرد مدل‌ها با استفاده از منحنی مشخصه عملکرد گیرنده (ROC) و شاخص مساحت زیر منحنی (AUC)، و صحت سنجی نقشه‌های تولیدی در مناطق

خطرناک (طبقات خطر زیاد و خیلی زیاد) با استفاده از ۳۰ درصد نمونه‌های استفاده‌نشده با معیارهای صحت کلی و ضریب کاپا مورد ارزیابی کمی قرار گرفت.

### نتایج و بحث

در این پژوهش، عملکرد چهار الگوریتم یادگیری ماشین و عمیق در پهنه‌بندی حساسیت زمین‌لغزش در حوزه آبخیز جنگلی ۸۵ استان گلستان مورد ارزیابی قرار گرفت. نتایج نشان داد که الگوریتم یادگیری عمیق CNN با کسب امتیاز AUC برابر ۰/۹۱۰، صحت کلی ۸۷/۷۲ درصد و ضریب کاپای ۰/۸۹۹ برای طبقات پرخطر (خطرناک و خیلی خطرناک) به‌عنوان کارآمدترین مدل شناسایی شد. تحلیل اهمیت متغیرها با استفاده از مدل برتر (CNN) نشان داد که عوامل فاصله از گسل و فاصله از رودخانه به‌ترتیب دارای بیش‌ترین اهمیت در وقوع زمین‌لغزش در منطقه مورد مطالعه هستند. این یافته کاملاً با انتظارات زمین‌شناختی و ژئومورفولوژیکی منطقه همخوانی دارد. نقشه نهایی حساسیت زمین‌لغزش تولیدشده توسط مدل CNN نشان داد که ۳۱/۴۶ درصد از مساحت حوزه (معادل تقریباً ۱۲۳۶۰ هکتار) در طبقه خطر خیلی زیاد قرار دارد.

### نتیجه‌گیری

یافته‌های این پژوهش به‌وضوح برتری و پتانسیل بالای الگوریتم‌های یادگیری عمیق، به‌ویژه معماری شبکه عصبی پیچشی (CNN) را در تهیه نقشه‌های حساسیت زمین‌لغزش با دقت بالا در مقایسه با الگوریتم‌های یادگیری ماشین تأیید کرد. نقشه تولیدشده می‌تواند به‌عنوان یک ابزار علمی معتبر و قدرتمند در اختیار مدیران و برنامه‌ریزان قرار گیرد تا با تمرکز بر نواحی پرخطر، اقدامات پیشگیرانه، مدیریت ریسک و برنامه‌ریزی برای کاربری اراضی ایمن را در اولویت قرار دهند. برای مطالعات آینده، تلفیق این مدل‌ها با الگوریتم‌های بهینه‌ساز، استفاده از داده‌های با قدرت تفکیک بالاتر برای غلبه بر محدودیت‌های داده‌های فعلی و توسعه چارچوب‌های هیبریدی که هم دقت و هم قابلیت تفسیرپذیری را افزایش دهند، پیشنهاد می‌شود.

**واژه‌های کلیدی:** پیش‌بینی حساسیت، جنگل‌های هیرکانی، شبکه عصبی پیچشی، مدلسازی مکانی، منحنی مشخصه عملکرد گیرنده

### مقدمه

شیب‌های تند، ویژگی‌های زمین‌شناسی بستر، بارندگی‌های شدید و فعالیت‌های انسانی گسترده، یکی از مناطق مستعد زمین‌لغزش در ایران محسوب می‌شود (Kornejady et al., 2018).

این امر لزوم ارائه راهکارهای مؤثر برای پیشگیری، کنترل و کاهش پیامدهای این پدیده را بیش‌ازپیش آشکار می‌سازد. تحولات اخیر در حوزه فناوری‌های فضایی و هوش مصنوعی، تحول شگرفی در مطالعات پهنه‌بندی حساسیت زمین‌لغزش ایجاد کرده است. پیشرفت‌های چشمگیر در سامانه‌های اطلاعات جغرافیایی (GIS)، سنجش‌ازدور (RS) و الگوریتم‌های داده‌کاوی، امکان تحلیل همزمان ده‌ها عامل مؤثر شامل فیزیوگرافی، هواشناسی و فعالیت‌های انسانی را فراهم ساخته است (Mohammadyari et al., 2018).

زمین‌لغزش به حرکت و جابجایی مواد تشکیل‌دهنده دامنه، از جمله سنگ‌های طبیعی، خاک، رسوبات مصنوعی، توده‌های یخی یا ترکیبی از آنها به سمت پایین شیب تحت تأثیر نیروی ثقل اطلاق می‌شود (Ganesh et al., 2023). این پدیده به‌عنوان یکی از مخرب‌ترین آشفته‌گی‌های طبیعی، سالانه خسارات گسترده‌ای به زیرساخت‌های حیاتی، سکونتگاه‌های انسانی و اکوسیستم‌های طبیعی وارد می‌کند (Destrange et al., 2024).

بر اساس گزارش‌های جهانی، زمین‌لغزش‌ها سالانه موجب مرگ صدها نفر و خسارات مالی میلیاردی در مقیاس جهانی می‌شوند (Petley et al., 2012). استان گلستان به‌دلیل شرایط خاص جغرافیایی، از جمله

۱۵ عامل زمین‌شناسی و محیطی به‌عنوان متغیرهای مستقل و ۱۷۴ رخداد زمین‌لغزش ثبت‌شده به‌عنوان متغیر وابسته استفاده کردند. داده‌ها به‌صورت تصادفی به دو بخش آموزشی (۷۰ درصد) و اعتبارسنجی (۳۰ درصد) تقسیم شدند. نتایج نشان داد که هر دو مدل از دقت بالایی برخوردارند، اما مدل جنگل تصادفی با مقدار AUC-ROC برابر ۰/۹۱۹ عملکرد بهتری نسبت به شبکه عصبی مصنوعی با مقدار ۰/۸۴۵ داشت. این مطالعه مؤید کارایی بالای مدل‌های یادگیری ماشین به‌ویژه جنگل تصادفی در پهنه‌بندی حساسیت زمین‌لغزش است.

Taheri et al., (2019) از یک الگوریتم ترکیبی نوین شامل کمترین مربعات ماشین بردار پشتیبان و کلونی زنبور عسل مصنوعی برای پهنه‌بندی حساسیت زمین‌لغزش در محدوده کوهستانی استان گلستان استفاده کردند. با به‌کارگیری ۱۲ معیار مؤثر و با دقت آموزشی ۸۶/۲۶ درصد و اعتبارسنجی ۸۲/۳ درصد، منطقه را به پنج طبقه حساسیت تقسیم‌بندی نمودند. نتایج نشان داد ۲۷/۹۳ درصد از مساحت منطقه در طبقات با حساسیت متوسط تا بسیار زیاد قرار دارد که ظرفیت پیش‌بینی بالای این مدل ترکیبی را نشان می‌دهد.

در سطح بین‌المللی نیز پژوهش‌های متعددی به مقایسه کارایی مدل‌های مختلف پرداخته‌اند. به‌عنوان مثال، Wu et al., (2025) در پژوهشی، مدل‌های یادگیری عمیق شامل CNN و RNN برای پیش‌بینی حساسیت زمین‌لغزش توسعه دادند. پژوهشگران از یک مجموعه‌داده جامع متشکل از ۱۹۸۹۸ نمونه مبتنی بر سوابق زمین‌لغزش و ۱۶ عامل تأثیرگذار در استان کوماموتوی ژاپن استفاده کردند. مدل پیشنهادی آنها از شبکه عصبی پیچشی (CNN) برای استخراج ویژگی‌های فضایی، شبکه حافظه بلندمدت-کوتاه‌مدت (LSTM) برای مدل‌سازی بهره برد.

نتایج تجربی نشان داد که این مدل ترکیبی به‌طور معنی‌داری از نظر معیارهای دقت، صحت و ROC-AUC عملکرد بهتری نسبت به روش‌های متعارف یادگیری ماشین دارد. این بهبود چشمگیر ناشی از قابلیت مدل در شناسایی ویژگی‌های مکانی است. این

در سال‌های اخیر، کاربرد روش‌های یادگیری ماشین در پیش‌بینی حساسیت زمین‌لغزش به‌عنوان الگوی نوین در مطالعات مخاطرات طبیعی مطرح شده است. مطالعات زیادی در داخل و خارج از ایران صورت گرفته است که می‌توان به تحقیقات Babarbi et al., (2025)، Sadati et al., (2024)، Dastranj et al., (2024)، Sephevand and Esfandiari et al., (2024)، Moharrami and Jellokhani-Beiranvand, (2024)، Shirani, Javidan et al., (2023)، Niarkii, (2023)، Rafiei-Sardovii and Naderi-Samani, (2022)، Karenjadi et al., Ghiyasi et al., (2022)، Lokesh (2025)، Ferreira et al., (2025)، (2020)، Fitriana et al., (2024)، Melati et al., (2024)، Doyran et al., (2023)، Mastouri et al., (2022) و Zhao et al., (2021) اشاره نمود.

در این راستا مطالعات متعددی به مقایسه کارایی این مدل‌ها در مناطق مختلف پرداخته‌اند که در ادامه به برخی از آنها اشاره می‌شود. Babarrabi et al., (2025) با استفاده از مدل‌های SVM و RF و بررسی ۶۱ نقطه لغزشی در حوضه تالار به پهنه‌بندی حساسیت زمین‌لغزش پرداختند.

نتایج این تحقیق نشان داد مدل ماشین بردار پشتیبان با (AUC=۰/۸۷۱) و جنگل تصادفی با (AUC=۰/۸۵۳) هر دو دارای دقت خیلی خوب هستند، اما ساختار ریاضی پیشرفته مدل ماشین بردار پشتیبان در مناطق با داده‌های محدود، عملکرد بهتری ارائه می‌دهد که این نتیجه با توجه به طبقه‌بندی ارائه‌شده برای سطح زیر منحنی (۰/۹-۰/۹، عالی، ۰/۹-۰/۸، خیلی خوب، ۰/۷-۰/۸، خوب، ۰/۶-۰/۷، متوسط و ۰/۵-۰/۶، ضعیف)، نشان داده شده است (Kleiman and Page, 2019) و همچنین نتایج حاکی از آن بود که مناطق با حساسیت بالا عمدتاً در بخش‌های مرتفع جنوبی، مرکز منطقه با شیب زیاد و حواشی رودخانه‌ها و جاده‌ها قرار داشتند.

Shirani and Naderi Samani, (2022) در مطالعه‌ای به تعیین عامل‌های مؤثر و ارزیابی حساسیت به زمین‌لغزش با استفاده از روش‌های جنگل تصادفی و شبکه عصبی مصنوعی در منطقه دوآب صمصامی استان چهارمحال و بختیاری پرداختند. پژوهشگران از

همچنین (Daviran et al., 2023)، با استفاده از سه مدل یادگیری ماشین (شبکه عصبی مصنوعی، ماشین بردار پشتیبان و جنگل تصادفی) و ۱۵ معیار مؤثر، مناطق مستعد زمین لغزش را در زیر حوضه طارم-خلخال پهنه‌بندی کردند. نتایج نشان داد جنگل تصادفی با  $AUC=0.93$  بهترین عملکرد را داشته است. با وجود پیشرفت‌های قابل توجه در این حوزه، هنوز چالش‌هایی وجود دارد. از جمله این چالش‌ها می‌توان به وابستگی عملکرد مدل‌ها به ویژگی‌های منطقه مورد مطالعه، نیاز به داده‌های با کیفیت و به‌روز و ضرورت توسعه مدل‌های ترکیبی برای افزایش دقت پیش‌بینی اشاره کرد.

با بررسی جامع مطالعات پیشین در حوزه پهنه‌بندی حساسیت زمین لغزش در استان گلستان، این نکته به‌وضوح آشکار می‌شود که اگرچه تحقیقات متعددی در این منطقه انجام شده، اما کلیه این مطالعات از روش‌های کلاسیک و مدل‌های آماری سنتی بهره برده‌اند و هیچ پژوهشی تاکنون به‌صورت جدی به به‌کارگیری الگوریتم‌های پیشرفته یادگیری ماشین و یادگیری عمیق در این منطقه نپرداخته است. این خلاء پژوهشی آشکار، لزوم انجام مطالعاتی با بهره‌گیری از روش‌های نوین هوش مصنوعی و الگوریتم‌های یادگیری عمیق را در مطالعات زمین لغزش به‌عنوان یک ضرورت علمی مطرح می‌سازد. مطالعه حاضر با هدف پر کردن این خلاء پژوهشی و با سه نوآوری اصلی نسبت به تحقیقات پیشین در گلستان انجام شده است.

(۱) استفاده از مدل‌های پیشرفته یادگیری عمیق (شبکه عصبی پیچشی CNN و شبکه عصبی بازگشتی RNN) برای اولین بار در این منطقه خاص، (۲) انجام ارزیابی مقایسه‌ای سیستماتیک بین عملکرد این مدل‌های عمیق با مدل‌های کلاسیک متداول یادگیری ماشین (SVM و RF) و (۳) تمرکز بر حوزه آبخیز جنگلی ۸۵ استان گلستان، به‌عنوان نمونه‌ای از اکوسیستم‌های هیرکانی با پوشش جنگلی انبوه نیازمند مطالعه‌ای اختصاصی و دقیق است؛ بنابراین، این پژوهش به دنبال ارائه یک ارزیابی دقیق‌تر و به‌روز از حساسیت زمین لغزش با استفاده از قوی‌ترین ابزارهای موجود است.

مطالعه پتانسیل بالای رویکردهای مبتنی بر یادگیری عمیق را برای افزایش قابلیت اطمینان پیش‌بینی حساسیت زمین لغزش در شرایط توپوگرافی پیچیده و آب‌وهوای پویا به‌وضوح نشان می‌دهد.

(Abdul Qadir and Chamar, 2025) در مطالعه‌ای باهدف بررسی قابلیت اطمینان نقشه‌های حساسیت زمین لغزش، سه مدل یادگیری ماشین (رگرسیون لجستیک، جنگل تصادفی و ماشین بردار پشتیبان) را در شرق قاهره ارزیابی کردند. آنها با جمع‌آوری ۱۴ عامل تأثیرگذار و ۳۶۶ نقطه نمونه، نشان دادند که همه مدل‌ها، توانستند امتیاز بالای ROC-AUC را به دست آورند.

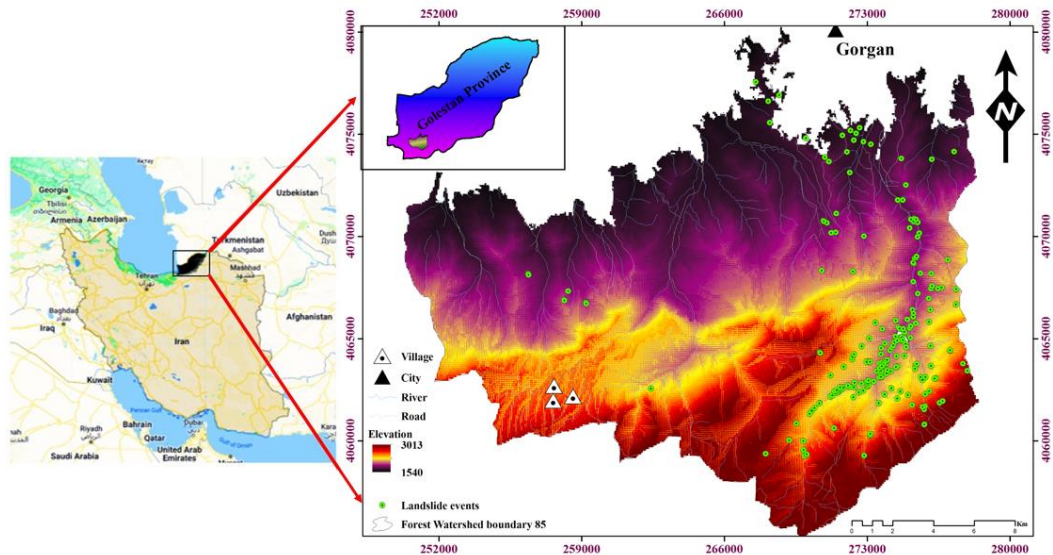
(Lokesh et al., 2025) در مطالعه‌ای با هدف شناسایی مناطق مستعد زمین لغزش برای مدیریت خطر، به نقشه‌برداری از حساسیت زمین لغزش در منطقه وایاناد، کرالای هند پرداختند. پژوهشگران از مجموعه داده‌هایی شامل ۱۱ لایه عامل (مانند ارتفاع، شیب، کاربری اراضی، بارش و زمین‌شناسی) و هفت مدل یادگیری ماشین و یادگیری عمیق شامل ماشین بردار پشتیبان، شبکه عصبی مصنوعی، رگرسیون لجستیک، جنگل تصادفی، ماشین گرادیان بوس‌تینگ، شبکه عصبی مکرر LSTM و شبکه عصبی عمیق استفاده کردند. مدل‌ها با استفاده از نقشه موجودی شامل ۲۹۸ نقطه زمین لغزش آموزش و اعتبارسنجی شدند. نتایج نشان داد که مدل جنگل تصادفی با دقت ۹۷ درصد بهترین عملکرد را داشته است. این مطالعه نشان می‌دهد که شناسایی مناطق پرخطر با این روش‌ها می‌تواند به کاهش مؤثر خسارات ناشی از زمین لغزش و برنامه‌ریزی بلندمدت کاربری اراضی منجر شود.

(Fitriana et al., 2024) در تحقیقی به مقایسه دو روش آماری (FR) و یادگیری ماشین (RF) برای ارزیابی حساسیت زمین لغزش در سومدانگ اندونزی پرداختند. این پژوهشگران با بررسی ۱۲ عامل مؤثر و داده‌های تاریخی، مدل‌هایی با دقت ۰/۸۸ (FR) و ۰/۸۱ (RF) براساس شاخص AUC توسعه دادند. نتایج نشان داد هر دو روش قابلیت بالایی در شناسایی مناطق با حساسیت بالا دارند و می‌توانند برای مدیریت ریسک زمین لغزش در منطقه مورد استفاده قرار گیرند.

## مواد و روش‌ها

**معرفی منطقه پژوهش:** پژوهش حاضر در حوزه جنگلی ۸۵ به مساحت تقریبی ۳۹۲۸۸ هکتار در استان گلستان انجام شد. حوزه جنگلی ۸۵ یکی از حوضه‌های ۱۰۴ گانه جنگلی جنگل‌های هیرکانی، در محدوده جغرافیایی بین ۱۲' ۵۴° تا ۳۱' ۵۴° طول شرقی و ۳۶' ۳۶° تا ۵۰' ۳۶° عرض شمالی قرار دارد.

پوشش غالب منطقه را جنگل‌های (۸۷/۶ درصد) تشکیل می‌دهند. این حوضه در استان گلستان و از نظر مرز سیاسی در محدوده شهرستان‌های گرگان و کردکوی واقع و توسط اداره منابع طبیعی و آبخیزداری شهرستان‌های گرگان و کردکوی مدیریت می‌شود (شکل ۱).



شکل ۱- موقعیت جغرافیایی، وضعیت توپوگرافی و پراکنش نقاط زمین‌لغزش منطقه مورد مطالعه در کشور و استان گلستان  
**Fig. 1.** Geographical location, topographic status, and distribution of landslide points in the study area within the country and Golestan Province

طبیعی و آبخیزداری استان گلستان تهیه شده بود و همچنین مطالعات پیشین گردآوری و پس از اصلاحات لازم در محیط GIS سازمان‌دهی شد. کلیه لایه‌های موردنیاز با فرمت و اندازه سلول یکسان (۳۰ متر × ۳۰ متر) تهیه شدند. این اندازه سلول بر اساس قدرت تفکیک مدل رقومی ارتفاع (DEM) با رزولوشن ۳۰ متر و برای حفظ همخوانی و یکپارچگی همه لایه‌ها انتخاب شد.

سلول‌هایی که محل رخداد پدیده زمین‌لغزش بودند شناسایی و به ازای هر سلول تمامی اطلاعات مربوط به ده عامل مؤثر بر وقوع زمین‌لغزش استخراج شد. به منظور ایجاد یک dataset متعادل و جلوگیری از سوگیری مدل، تعداد نقاط غیرلغزشی، به تعداد مساوی با نقاط لغزشی (۲۴۷ نقطه) به صورت کاملاً تصادفی از مناطقی خارج از محدوده‌های شناسایی شده زمین‌لغزش انتخاب شدند. برای هر یک از این نقاط

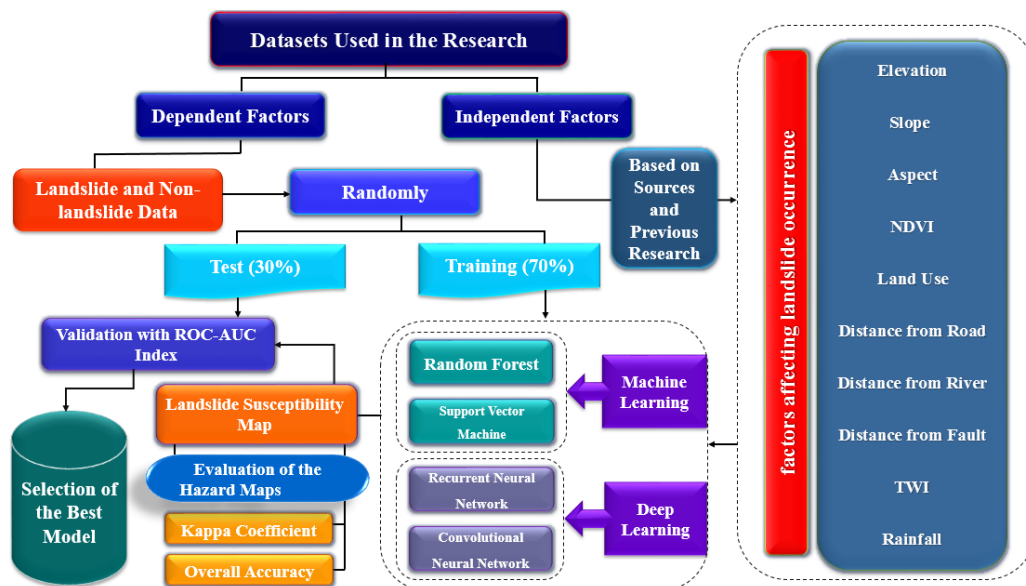
**روش تحقیق:** برای انجام این مطالعه از طریق بررسی جامع منابع علمی اقدام به شناخت، جمع‌آوری و مستندسازی عوامل مؤثر بر وقوع زمین‌لغزش شد (Abdelkader et al., Pourghasemi et al., 2023). Sun et al., Thammaboribal et al., 2025, 2025). ده عامل کلیدی و مؤثر بر تحلیل وقوع زمین‌لغزش به‌عنوان عوامل پیش‌بینی‌کننده (مستقل)، شامل ارتفاع، درصد شیب، جهت شیب، شاخص رطوبت توپوگرافی (TWI)، شاخص تفاضل نرمال شده پوشش گیاهی (NDVI)، کاربری اراضی، فاصله از جاده، فاصله از رودخانه، فاصله از گسل و میانگین بارندگی سالانه در نرم‌افزار ArcGIS به صورت رستری تهیه شد.

سپس، نقشه پراکنش زمین‌لغزش‌های منطقه به‌عنوان عوامل وابسته با استفاده از داده‌های مکانی زمین‌لغزش‌های منطقه که توسط اداره کل منابع

مطالعات مشابه (Huang et al., Babarrabi et al., 2025) Dastaranj and Karimi Sanghini, et al., (2025) (2022)، به صورت تصادفی تقسیم شدند. سپس نقشه خطر زمین لغزش با استفاده از روش‌های یادگیری ماشین (RF و SVM) و یادگیری عمیق (CNN و RNN) تهیه شد و کارایی مدل‌ها با استفاده از شاخص‌های ROC-AUC و صحت سنجی نقشه‌های طبقات خطر با معیارهای صحت کلی و ضریب کاپا در محل نمونه‌های ارزیابی، مورد ارزیابی قرار گرفت و در نهایت بهترین مدل تعیین شد.

غیرلغزشی نیز، مقادیر مربوط به ده عامل مؤثر استخراج شد. به منظور تشخیص پهنه‌های حساس به وقوع زمین لغزش، به سلول‌هایی که محل وقوع زمین لغزش بودند ارزش یک و عدم وقوع زمین لغزش ارزش صفر اختصاص داده شد.

برای مدل‌سازی خطر زمین لغزش، داده‌ها (شامل ۴۹۴ نقطه) با استفاده از تابع train\_test\_split از کتابخانه scikit-learn در پایتون، به نسبت ۷۰ درصد (۳۴۶ نقطه) برای آموزش و ۳۰ درصد (۱۴۸ نقطه) برای اعتبارسنجی، مطابق با روش‌شناسی پرکاربرد در



شکل ۲- نمودار جریان‌ی پهنه‌بندی حساسیت رخداد زمین لغزش

Fig. 2. Flowchart of landslide susceptibility zoning

کاربری اراضی، فاصله از جاده، فاصله از رودخانه، فاصله از گسل و میانگین بارندگی سالانه در محیط سامانه اطلاعات جغرافیایی (GIS) آماده‌سازی شد. لایه‌های ارتفاع، شیب و جهت شیب از مدل رقومی ارتفاع (DEM) حاصل از داده‌های SRTM<sup>1</sup> با قدرت تفکیک قدرت تفکیک زمینی ۳۰ متر و با استفاده از نرم‌افزار ArcGIS 10.8.2 تهیه شد.

از تابع فاصله اقلیدسی برای آماده‌سازی لایه‌های فاصله از جاده، فاصله از رودخانه و فاصله از گسل در محیط GIS استفاده شد. لایه شاخص NDVI به‌عنوان نماینده پوشش گیاهی، از پردازش تصاویر ماهواره لندست ۸ (OLI) در پلتفرم Google Earth Engine

تهیه نقشه‌ی عوامل مؤثر بر وقوع زمین لغزش: مطالعه پهنه‌بندی حساسیت زمین لغزش مستلزم شناسایی و گردآوری داده‌های مربوط به عوامل تأثیرگذار در پیش‌بینی است. بر اساس بررسی منابع و مطالعات پیشین (Pourghasemi et al., 2023) Zhou et al., Pourghasemi and Rahmati, 2018 (2018) و تحلیل شرایط منطقه‌ای، شاخص‌های کلیدی مؤثر در رخداد زمین لغزش در محدوده پژوهش تعیین و تحلیل شد.

بر این اساس در این مطالعه ده عامل مؤثر بر وقوع زمین لغزش مطابق جدول ۱ شامل ارتفاع، درصد شیب، جهت شیب، شاخص رطوبت توپوگرافی (TWI)، شاخص تفاضل نرمال شده پوشش گیاهی (NDVI)،

<sup>1</sup> Shuttle Radar Topography Mission

طبقات خطر با استفاده از صحت کلی و ضریب کاپا مورد سنجش قرار گرفتند.

**جنگل تصادفی (RF<sup>1</sup>):** جنگل تصادفی یک الگوریتم یادگیری ماشین مبتنی بر روش‌های مجموعه‌ای<sup>۲</sup> مبتنی بر مدلسازی درختان تصمیم، با ترکیب خروجی چندین درخت تصمیم‌گیری، دقت پیش‌بینی را افزایش و واریانس را کاهش می‌دهد (Norouzi, Goshbalag and Nadiri, 2018).

این مدل با ایجاد مجموعه‌ای از درخت‌های تصمیم و تجمیع نتایج آنها، از مشکل بیش‌برازش جلوگیری می‌کند. هر درخت تصمیم به‌صورت مستقل بر روی یک زیرمجموعه تصادفی از داده‌های آموزشی (با روش Bootstrap Aggregating یا Bagging) آموزش می‌بیند. درنهایت، نتایج تمام درخت‌ها برای تصمیم‌گیری نهایی تجمیع می‌شود (رای اکثریت برای طبقه‌بندی یا میانگین برای رگرسیون). جنگل تصادفی به‌دلیل توانایی بالا در پردازش داده‌های با ابعاد زیاد و عدم حساسیت به مقیاس‌پذیری متغیرها، به‌طور گسترده در مطالعات پهنه‌بندی حساسیت زمین‌لغزش مورد استفاده قرار گرفته است.

مدل با استفاده از کتابخانه یادگیری ماشین در پایتون پیاده‌سازی شد و پارامترهای کلیدی آن شامل تعداد درختان، عمق بیشینه درخت و حداقل نمونه‌های موردنیاز برای تقسیم یک گره، پس از انجام فرایند بهینه‌سازی و آزمایش‌های متعدد تعیین شدند. یکی از مزایای کلیدی این مدل، قابلیت محاسبه اهمیت متغیرها است که عوامل کلیدی مؤثر در وقوع زمین‌لغزش در منطقه مورد مطالعه را شناسایی می‌کند (Rodriguez et al., 2012).

**ماشین بردار پشتیبان (SVM<sup>3</sup>):** مدل ماشین بردار پشتیبان یکی از روش‌های قدرتمند در حوزه یادگیری ماشین است که هم در مسائل طبقه‌بندی و هم در رگرسیون کاربرد دارد. این مدل بر پایه مبانی ریاضی و تئوری یادگیری استوار است و برای اولین بار توسط (Vapnik و Cortes, 1995) معرفی شد (Sepahvand et al., 2018). SVM به‌دلیل

استخراج شد. از آنجایی که پوشش گیاهی یک عامل پویاست، برای به دست آوردن نمایه پایدار و کاهش نویزهای فصلی و سالانه، میانگین شاخص NDVI برای فصل رویش (خرداد تا شهریور) در یک دوره پنج‌ساله (۱۳۹۵ تا ۱۴۰۰) محاسبه شد. این بازه زمانی با دوره وقوع اکثر زمین‌لغزش‌های موجود در کاتالوگ منطبق است تا شرایط محیطی مؤثر در وقوع آنها را به بهترین شکل نشان دهد.

همچنین شاخص رطوبت توپوگرافی (TWI)، از طریق رابطه (۱)، در محیط نرم‌افزار GIS تهیه شد (Destrange et al., 2024).

$$TWI = \ln(\alpha / \tan\beta) \quad (1)$$

که در این رابطه،  $\alpha$  نشان‌دهنده زهکشی شیب بالا در واحد طول و  $\beta$  بیانگر شیب متوسط منطقه است. لایه میانگین بارندگی سالانه نیز به‌عنوان یک عامل مؤثر از محصول بازتحلیل ERA5 در پلتفرم Google Earth Engine برای دوره بلندمدت (۲۰۰۵ تا ۲۰۲۴) استخراج شد. این محصول بر اساس مشاهدات جهانی، الگوی مکانی میانگین بارش را با دقت مناسبی ارائه می‌دهد.

**تهیه نقشه حساسیت زمین‌لغزش با استفاده از مدل‌های یادگیری ماشین و عمیق:** این پژوهش با بهره‌گیری از چارچوبی نوین، الگوریتم‌های یادگیری ماشین (شامل جنگل تصادفی و ماشین بردار پشتیبان) و یادگیری عمیق (شامل شبکه‌های عصبی بازگشتی و شبکه‌های عصبی پیچشی) را برای پهنه‌بندی حساسیت زمین‌لغزش به کار گرفت. پس از آماده‌سازی لایه‌های اطلاعاتی و تقسیم‌بندی داده‌ها به مجموعه‌های آموزش و اعتبارسنجی، مدل‌های یادگیری ماشین و عمیق در محیط پایتون پیاده‌سازی شدند. از کتابخانه‌های Scikit-learn برای پیاده‌سازی مدل‌های جنگل تصادفی (RF) و ماشین بردار پشتیبان (SVM) و از کتابخانه TensorFlow برای پیاده‌سازی شبکه‌های عصبی پیچشی (CNN) و بازگشتی (RNN) استفاده شد (Géron, 2017; Heaton, 2020).

درنهایت، دقت پیش‌بینی هر مدل به‌صورت کمی اندازه‌گیری شد. عملکرد مدل‌ها با محاسبه سطح زیر منحنی (AUC) در نمودار ROC و نقشه‌های تولیدی

<sup>1</sup> Random Forest

<sup>2</sup> Ensemble Learning

<sup>3</sup> Support Vector Machine

در نهایت به پنج طبقه حساسیت تبدیل شدند تا نقشه نهایی پهنه‌بندی حاصل شود.

**شبکه عصبی بازگشتی<sup>۳</sup>:** شبکه‌های عصبی بازگشتی با معماری تخصصی خود، توانایی پردازش داده‌های سری زمانی پیچیده مانند تغییرات بارندگی و سایر عامل‌های دینامیک مؤثر در زمین‌لغزش را دارند (Habumugisha et al., 2022). این مدل‌ها با بهره‌گیری از واحدهای LSTM که دارای سه گیت کنترل (ورودی، فراموشی و خروجی) هستند، می‌توانند وابستگی‌های بلندمدت را در توالی‌های زمانی طولانی شناسایی و حفظ کنند (Yang et al., 2024).

ترکیب این شبکه‌ها با داده‌های ماهواره‌ای چند زمانه مانند تصاویر NDVI دقت پیش‌بینی‌ها را به‌طور چشمگیری افزایش می‌دهد (Habumugisha et al., 2022). این سیستم‌ها قادرند الگوهای پنهان در داده‌های اقلیمی و محیطی را استخراج کرده و رابطه آنها را با وقوع زمین‌لغزش مدل‌سازی کنند. در نهایت، RNN های مبتنی بر LSTM با تحلیل همزمان داده‌های تاریخی و جاری، ابزار قدرتمندی برای پیش‌بینی خطر زمین‌لغزش در مقیاس‌های زمانی مختلف فراهم می‌کنند (Yang et al., 2024).

معماری شبکه شامل لایه‌های بازگشتی با واحدهای حافظه بلند-کوتاه‌مدت برای یادگیری وابستگی‌های زمانی و لایه‌های کاملاً متصل برای تولید خروجی نهایی بود. پارامترهای کلیدی شامل تعداد واحدهای بازگشتی و تابع فعال‌ساز پس از آزمایش‌های مکرر و بررسی نتایج عملکردی مدل تعیین شدند. خروجی مدل که احتمال وقوع زمین‌لغزش را برای هر سلول پیش‌بینی می‌کرد، پس از پردازش نهایی در محیط سیستم اطلاعات جغرافیایی، به نقشه پهنه‌بندی حساسیت زمین‌لغزش تبدیل شد.

**شبکه عصبی پیچشی<sup>۴</sup>:** به‌عنوان یک روش یادگیری عمیق، به‌طور گسترده‌ای در پردازش تصویر برای طبقه‌بندی تصویر، شناسایی اشیاء و تقسیم‌بندی معنایی استفاده می‌شود (Indu and Barki, 2012). این روش محدودیت‌های رویکردهای یادگیری ماشین سنتی را برطرف کرده و به‌دقت بالاتری در بسیاری از

توانایی بالا در پردازش داده‌های پیچیده و غیرخطی، به یکی از پرکاربردترین الگوریتم‌ها در علوم مختلف تبدیل شده است. مدل‌های SVM بر اساس تئوری یادگیری نظارتی توسعه یافته‌اند و به‌عنوان یک چارچوب نوین در طبقه‌بندی و پیش‌بینی داده‌ها شناخته می‌شوند. اساس کار این روش، یافتن یک ابرصفحه بینه<sup>۱</sup> است که بتواند داده‌های متعلق به طبقه‌های مختلف را با حداکثر حاشیه از یکدیگر جدا کند. در مواردی که داده‌ها به‌صورت خطی تفکیک‌پذیر باشند، SVM از بین تمام مرزهای تصمیم‌گیری ممکن، خطی را انتخاب می‌کند که بیشترین فاصله را تا نزدیک‌ترین نقاط هر طبقه (بردارهای پشتیبان) داشته باشد (Singh et al., 2019).

از جمله مزایای SVM می‌توان به توانایی آن در کار با داده‌های با ابعاد بالا و همچنین قابلیت استفاده از توابع هسته<sup>۲</sup> برای حل مسائل غیرخطی اشاره کرد. این ویژگی‌ها باعث شده است که SVM در حوزه‌های مختلفی همچون پردازش تصویر، تشخیص الگو، بیوانفورماتیک و تحلیل داده‌های ژئوفیزیکی مورد استفاده قرار گیرد. با توجه به قدرت و انعطاف‌پذیری بالای SVM، این مدل همچنان به‌عنوان یکی از گزینه‌های اصلی در حل مسائل پیچیده یادگیری ماشین مطرح است (Kalantar et al., 2018).

در این پژوهش، از این مدل برای طبقه‌بندی مناطق مستعد و غیرمستعد زمین‌لغزش استفاده شد. با توجه به حساسیت این الگوریتم به مقیاس داده‌ها، کلیه عوامل مؤثر بر وقوع زمین‌لغزش مورد پیش‌پردازش و نرمال‌سازی قرار گرفتند. از تابع کرنل شعاعی پایه به‌دلیل انعطاف‌پذیری بالا و توانایی آن در مدل‌سازی مسائل غیرخطی پیچیده استفاده شد. پارامترهای کلیدی مدل شامل پارامتر هزینه و پارامتر کرنل پس از انجام آزمایش‌های سیستماتیک و مقایسه عملکرد مدل در سناریوهای مختلف انتخاب شدند. مدل آموزش‌دیده مقادیر تصمیم را برای هر سلول در منطقه مطالعاتی برگرداند که این مقادیر به‌عنوان شاخصی از حساسیت به زمین‌لغزش تفسیر شده و

<sup>3</sup> Recurrent Neural Network (RNN)

<sup>4</sup> Convolutional Neural Network (CNN)

<sup>1</sup> Hyperplane

<sup>2</sup> kernel functions

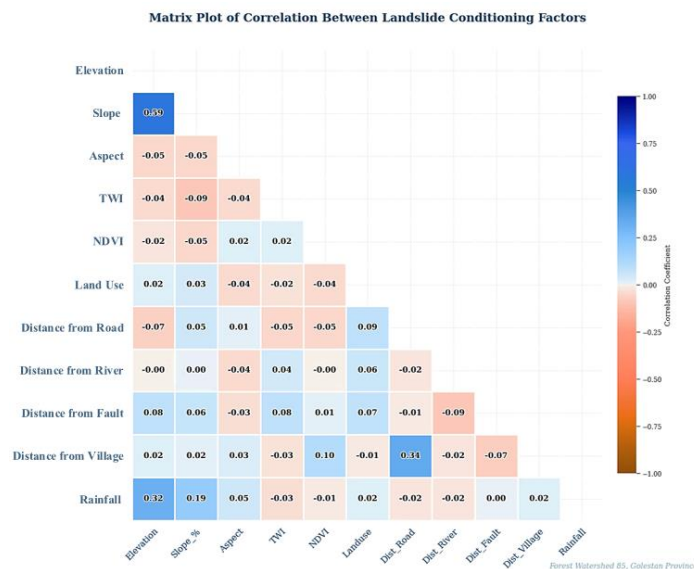
که خروجی نهایی آن نقشه پهنه‌بندی حساسیت زمین لغزش بود.

### نتایج و بحث

**تحلیل ماتریس همبستگی بین عوامل مؤثر در وقوع زمین لغزش:** شکل ۳، ماتریس همبستگی بین ده عامل مؤثر در وقوع زمین لغزش را نشان می‌دهد. همان‌طور که مشاهده می‌شود، به‌طور کلی هیچ همبستگی بسیار قوی (بالای ۰/۸) بین جفت عوامل مختلف وجود ندارد که نشان‌دهنده استقلال قابل قبول متغیرهای ورودی و مناسب بودن آنها برای مدل‌سازی است. بالاترین همبستگی مثبت (۰/۵۹) بین درصد شیب و ارتفاع مشاهده شد. با توجه به مقادیر محاسبه‌شده، می‌توان نتیجه گرفت که تمامی عوامل انتخاب‌شده را می‌توان با اطمینان وارد فرآیند مدل‌سازی کرد، چراکه خطر همخطی چندگانه شدید که منجر به ناپایداری مدل شود، وجود ندارد. این موضوع صحت و اعتبار نتایج مدل‌سازی را تضمین می‌کند.

حوزه‌های کاربردی دست یافته است. با این حال، نیاز به بهبود مشکل پیچیدگی محاسباتی این مدل همچنان احساس می‌شود (Custodio., 2025). یکی از راهکارهای پیشنهادی برای کاهش پیچیدگی محاسباتی، استفاده از شبکه‌های عصبی پیچشی با ساختارهای بهینه‌سازی شده و انتخاب ویژگی‌های مؤثر است که می‌تواند به بهبود کارایی مدل کمک کند. این تغییرات می‌توانند به افزایش سرعت پردازش و کاهش مصرف منابع محاسباتی منجر شوند (Kumar and Lopez, 2016).

معماری شبکه شامل لایه‌های پیچشی برای استخراج ویژگی‌های محلی، لایه‌های ادغام برای کاهش ابعاد و حفظ ویژگی‌های کلیدی و لایه‌های کاملاً متصل برای طبقه‌بندی نهایی بود. پارامترهای کلیدی شبکه شامل تعداد فیلترها، اندازه پنجره پیچشی و تابع فعال‌ساز پس از آزمایش‌های تجربی و بررسی عملکرد مدل بهینه شدند. مدل آموزش‌دیده بر روی کل منطقه مطالعاتی سلول به سلول اعمال شد و احتمال وقوع زمین لغزش برای هر سلول پیش‌بینی شد.



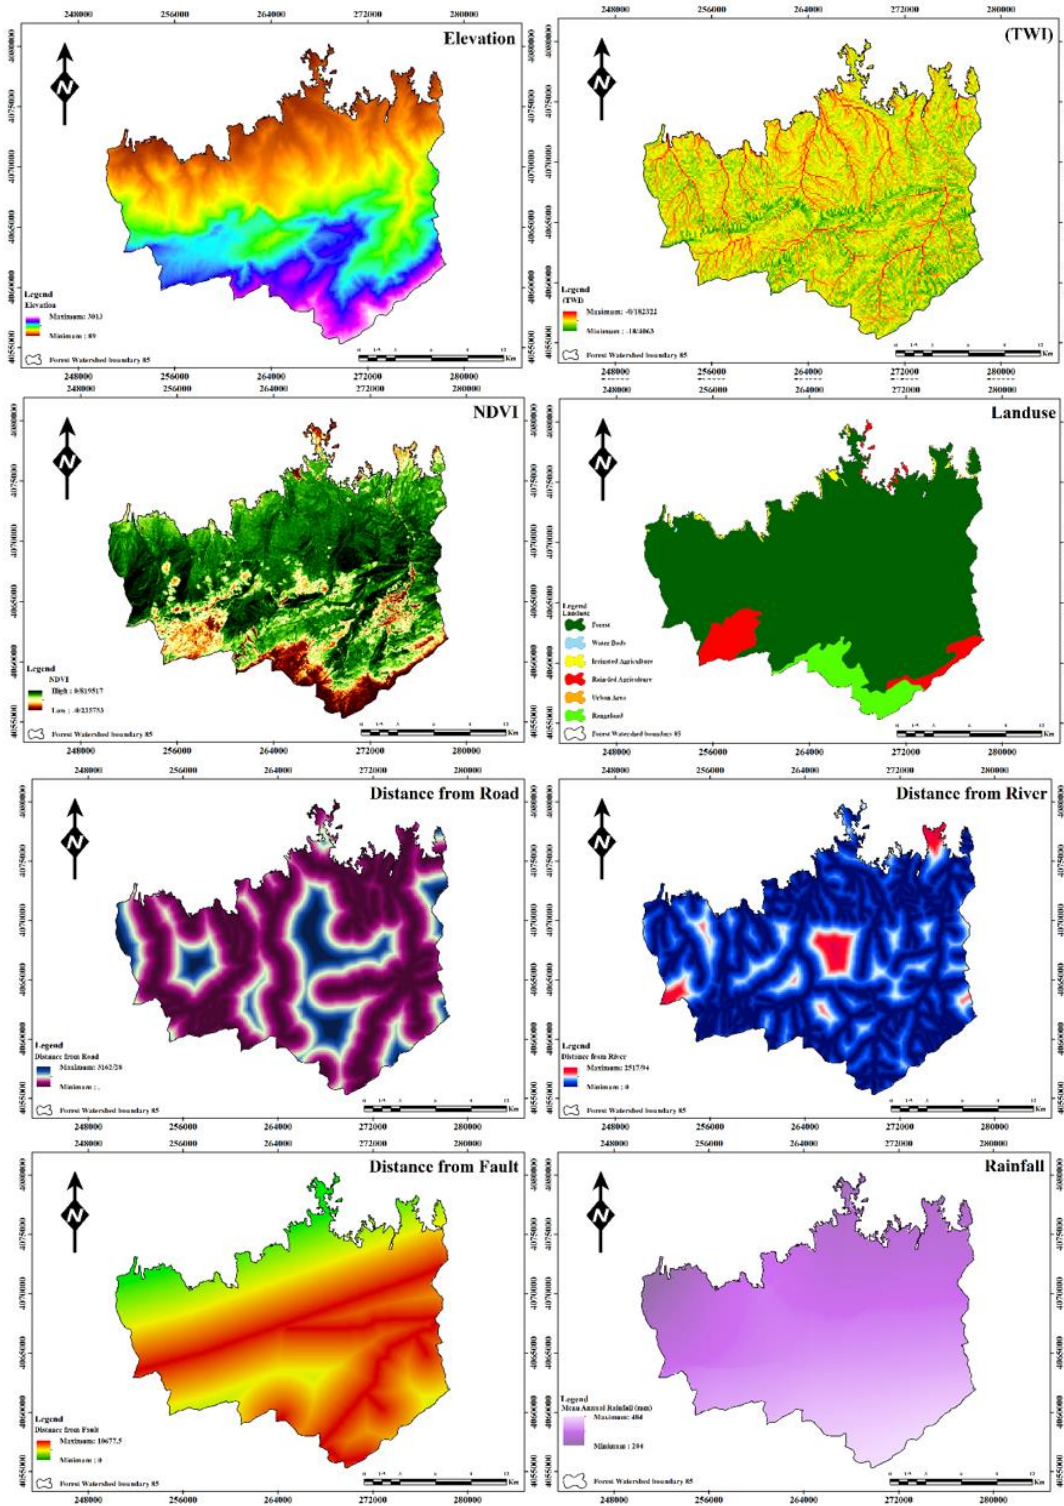
شکل ۳- ماتریس همبستگی بین عوامل مؤثر در وقوع زمین لغزش

Fig. 3. Correlation matrix between factors affecting landslide occurrence

فاصله از جاده، فاصله از رودخانه، فاصله از گسل و میانگین بارندگی سالانه به‌عنوان عوامل مؤثر در وقوع خطر زمین لغزش در منطقه مورد بررسی شناسایی و اقدام به تهیه و برآورد آنها شد (شکل ۴).

### تهیه لایه‌های مؤثر در وقوع زمین لغزش

اطلاعات ارتفاع حوضه، درصد شیب، جهت شیب، شاخص رطوبت توپوگرافی (TWI)، شاخص تفاضل نرمال شده پوشش گیاهی (NDVI)، کاربری اراضی،



شکل ۴- نقشه عوامل مؤثر در رخداد زمین لغزش  
 Fig. 4. Maps of factors affecting landslide occurrence

از هر مدل را به صورت بصری مقایسه می‌کند، شکل ۶ و جدول ۱ نیز به صورت کمی، توزیع مساحت و درصد هر طبقه خطر را برای هر الگوریتم نشان می‌دهند. تحلیل دقیق داده‌های کمی جدول ۱ و الگوهای فضایی مشاهده شده در شکل ۵، تفاوت‌هایی را در

نقشه حساسیت زمین لغزش حوضه: مدل‌سازی حساسیت زمین لغزش توسط چهار مدل SVM، RF، RNN و CNN انجام و نقشه‌های نهایی خطر به پنج طبقه خطر (خیلی کم، کم، متوسط، زیاد، خیلی زیاد) طبقه‌بندی شدند. شکل ۵ نقشه‌های پهنه‌بندی حاصل

درصد از عرصه را در محدوده پرخطر شناسایی کرده است. این الگو حاکی از قدرت تفکیک بالا و اطمینان بیشتر مدل در جداسازی قطعی مناطق پرخطر از امن است. تمرکز قاطع بر نواحی با بیشترین پتانسیل خطر و کاهش سهم مناطق با خطر مبهم (متوسط)، ابزاری کارآمد و قابل اعتماد برای تخصیص بهینه منابع مدیریتی در اختیار تصمیم‌گیرندگان قرار می‌دهد.

**نتایج ارزیابی کارایی مدل‌های یادگیری ماشین و یادگیری عمیق:** ارزیابی کمی عملکرد مدل‌ها با استفاده از معیارهای  $AUC^1$ ، صحت کلی<sup>۲</sup> و ضریب کاپا<sup>۳</sup> انجام شد که نتایج آن در جدول ۲ و شکل ۷ ارائه شده است. تحلیل این شاخص‌ها به وضوح برتری یکی از مدل‌ها را نشان می‌دهد. مدل شبکه عصبی پیچشی (CNN) با کسب امتیاز AUC برابر ۰/۹۱۰ در مقایسه با مدل‌های جنگل تصادفی (۰/۸۶۰)، ماشین بردار پشتیبان (۰/۸۲۰) و شبکه عصبی بازگشتی (۰/۸۹۰)، بالاترین قدرت تشخیصی را در تمایز بین مناطق مستعد و غیرمستعد وقوع زمین‌لغزش دارا است.

این برتری در سایر معیارهای ارزیابی نیز کاملاً مشهود است، به طوری که مدل CNN با صحت کلی ۸۷/۷۲ درصد و ضریب کاپای ۰/۸۹۹، عملکردی به مراتب بالاتر از سایر الگوریتم‌ها نشان داد. ضریب کاپای نزدیک به ۰/۹ نشان‌دهنده توافق عالی بین نقشه پیش‌بینی‌شده و داده‌های مشاهداتی است و تأکید می‌کند که دقت بالای مدل صرفاً ناشی از تصادف نیست.

پس از مدل CNN، مدل RNN با امتیاز AUC برابر ۰/۸۹۰ و صحت کلی ۸۶/۵۴ درصد در رتبه دوم قرار گرفت که نشان می‌دهد معماری‌های یادگیری عمیق، حتی با وجود محدودیت حجم داده، توانایی استخراج الگوهای پیچیده‌تری را نسبت به مدل‌های کلاسیک یادگیری ماشین دارند. در میان مدل‌های کلاسیک، مدل RF با AUC برابر ۰/۸۶۰ و صحت کلی ۸۵/۶۹ درصد عملکرد به نسبت بهتری را نسبت به مدل SVM (با AUC برابر ۰/۸۲۰ و صحت کلی

درک فضایی خطر زمین‌لغزش توسط هر مدل آشکار می‌سازد.

این تفاوت‌ها نه تنها در دقت آماری، که در نحوه توزیع مکانی طبقات پرخطر و در نتیجه، در اولویت‌بندی مناطق برای مدیریت نیز مشهود است. در میان مدل‌های یادگیری ماشین، مدل جنگل تصادفی (RF) یک توزیع خطر نسبتاً محافظه‌کارانه را نشان می‌دهد، به طوری که ۳۱/۶۷ درصد از مساحت حوضه (معادل ۱۲۴۴۱/۱۱ هکتار) در طبقه خیلی زیاد قرار گرفته است و سهم طبقات متوسط و زیاد در مجموع ۳۸/۵۰ درصد است. این الگو حاکی از آن است که مدل RF مناطق با پتانسیل خطر بسیار بالا را به صورت متمرکزتر و محدودتر شناسایی می‌کند.

در مقابل، مدل ماشین بردار پشتیبان (SVM) رویکردی متفاوت دارد و حدود نیمی از مساحت حوضه (۴۸/۸۹ درصد معادل ۱۹۲۰۷/۳۹ هکتار) را در پرخطرترین طبقه (خیلی زیاد) قرار می‌دهد. این رویکرد بسیار سخت‌گیرانه، همراه با تخصیص ۲۴/۵۶ درصد دیگر به طبقه زیاد، نشان می‌دهد که این مدل تمایل دارد تا بخش وسیعی از عرصه را به‌عنوان منطقه پرخطر طبقه‌بندی کند که اگرچه برای برنامه‌ریزی‌های احتیاطی شدید مفید است، اما ممکن است باعث تخصیص غیربهینه منابع در مناطقی با خطر واقعی پایین‌تر شود.

در سوی دیگر، مدل‌های یادگیری عمیق نیز الگوهای متمایزی ارائه کردند. توزیع خطر در مدل شبکه عصبی بازگشتی (RNN) متعادل‌تر به نظر می‌رسد، به طوری که مجموع مساحت طبقات زیاد و خیلی زیاد ۵۷/۶۶ درصد است که بین دو مدل RF و SVM قرار می‌گیرد. این مدل نیز مشابه RF، سهم قابل توجهی (۳۰/۰۵ درصد) را به طبقه متوسط اختصاص داده که نشان‌دهنده در نظرگیری یک پهنه گذار بین مناطق پرخطر و کم‌خطر است. در نهایت، الگوی توزیع خطر در مدل شبکه عصبی پیچشی (CNN) به‌عنوان مدل برتر، از نظر کارشناسی و منطق زمین‌شناختی، قابل توجه و بهینه به نظر می‌رسد.

این مدل با تخصیص ۳۱/۴۶ درصد (۱۲۳۶۰/۰۰ هکتار) به طبقه خیلی زیاد و ۲۷/۱۶ درصد (۱۰۶۷۱/۹۶ هکتار) به طبقه زیاد، در مجموع ۵۸/۶۲

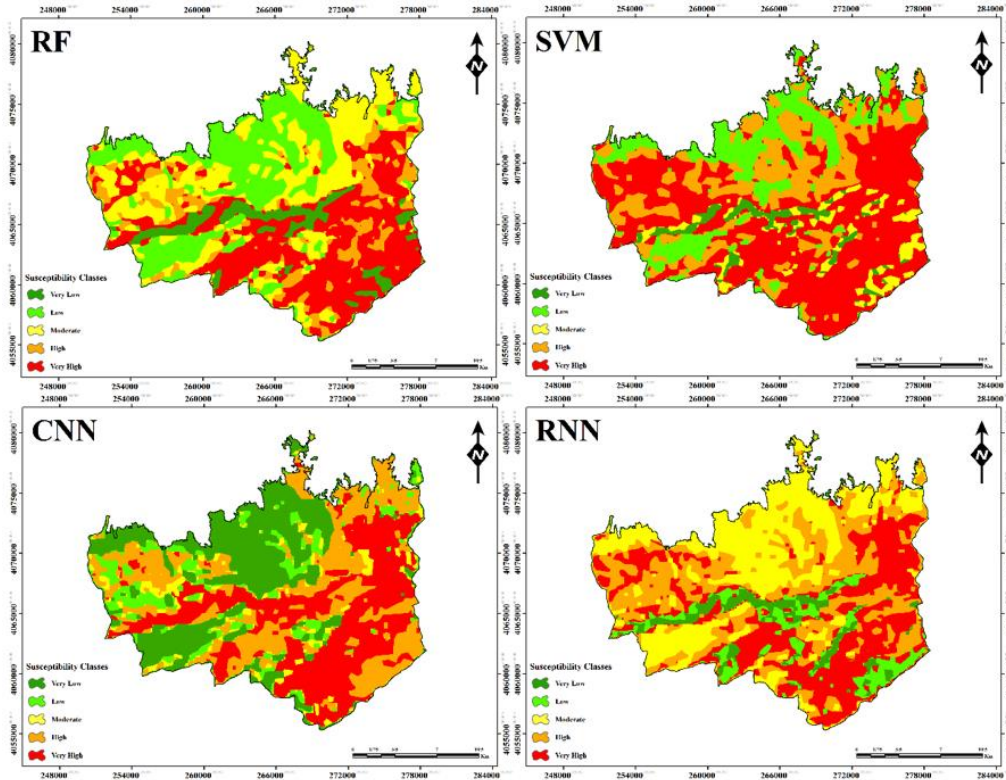
<sup>1</sup> Area Under Curve

<sup>2</sup> Overall Accuracy

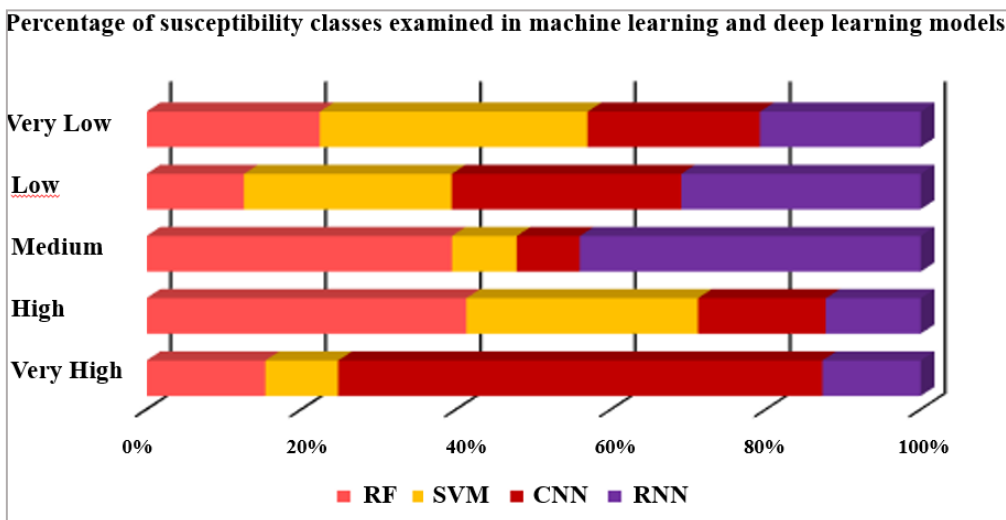
<sup>3</sup> Kappa Coefficient

بیشتر از مدل ماشین بردار پشتیبان برآورد شده است. به طور کلی، رتبه بندی نهایی عملکرد مدل ها بر اساس  $CNN > RNN > RF > SVM$  است.

۸۵/۱۹ درصد) ارائه نمود. این یافته که دقت مدل RF کمی بیشتر از SVM برآورد شده است، که با نتایج مطالعات انجام شده توسط Zhao et al., (2021) و Shirani and Naderi Samani (2022) همخوانی دارد که ادعا کرده بودند دقت مدل جنگل تصادفی کمی



شکل ۵- نقشه های پهنه بندی حساسیت رخداد زمین لغزش در مدل های مختلف یادگیری ماشین و یادگیری عمیق  
Fig. 5. Landslide susceptibility zonation maps using different machine learning and deep learning models




شکل ۶- درصد مساحت طبقات خطر در مدل های مختلف یادگیری ماشین و یادگیری عمیق مورد بررسی  
Fig 6. Percentage area of susceptibility classes in the different evaluated machine learning and deep learning models

جدول ۱- مساحت و درصد مساحت طبقه‌های خطر در الگوریتم‌های یادگیری ماشین و یادگیری عمیق مورد بررسی

Table 1. Area and percentage area of risk classes in the evaluated machine learning and deep learning algorithms

Susceptibility Classes	RF		SVM		CNN		RNN	
	Area (Ha)	(%)	Area (Ha)	(%)	Area (Ha)	(%)	Area (Ha)	(%)
Very Low	2562.16	6.52	1565.56	3/98	10419.14	26.52	2115.45	5.38
Low	9156.62	23.31	6630.04	16.88	3654.52	9.30	2714.67	6.91
Moderate	10582.00	26.93	2234.74	5.69	2182.18	5.55	11804.76	30.05
High	4545.92	11.57	9650.06	24.56	10671.96	27.16	11121.60	28.31
Very High	12441.11	31.67	12207.39	48.89	12360.00	31.46	11531.32	29.35
Total Sum	39287.8	100	39287.8	100	39287.8	100	39287.8	100



شکل ۷- منحنی مشخصه عملکرد گیرنده و مساحت زیر منحنی مربوط به مدل‌های مختلف

Fig. 7. Receiver operating characteristic (ROC) curve and area under the curve (AUC) for different models

جدول ۲- ارزیابی کمی عملکرد مدل‌ها در پهنه‌بندی حساسیت زمین لغزش

Table 2. Quantitative evaluation of model performance in landslide susceptibility zoning

Evaluation Criteria	RF	SVM	CNN	RNN
AUC	0.860	0.820	0.910	0.890
Overall Accuracy (%)	85.69	85.19	87.72	86.54
Kappa Coefficient	0.852	0.833	0.899	0.865


عامل ارتفاع با اهمیت ۰/۱۳ و درصد شیب اهمیت حدود ۰/۱۱ به ترتیب در رتبه‌های سوم و چهارم اهمیت قرار دارند. عوامل فاصله از جاده و NDVI (حدود ۰/۰۷) با اهمیت‌های کمتر شناسایی شدند. در نهایت، عامل کاربری اراضی با کمترین میزان اهمیت (حدود ۰/۰۵) در مدل‌سازی حضور داشت.

به‌طور کلی، این رتبه‌بندی گویای غلبه عوامل زمین‌شناختی (فاصله از گسل) و هیدروولوژیکی (فاصله از رودخانه) بر سایر عوامل در کنترل ناپایداری‌های دامنه‌ای در منطقه مورد مطالعه است. نقش کم‌رنگ عوامل انسانی مانند فاصله از جاده و کاربری اراضی نشان می‌دهد که شرایط طبیعی در مقایسه با فعالیت‌های بشری، تأثیر تعیین‌کننده‌تری در ایجاد زمین‌لغزش‌های این حوزه آبخیز جنگلی دارند.

تحلیل اهمیت متغیرهای مؤثر: نتایج حاصل از تحلیل اهمیت متغیرها در مدل بهینه CNN (شکل ۸) نشان می‌دهد که از میان ده عامل مورد بررسی، عامل فاصله از گسل با بیشترین میزان اهمیت (حدود ۰/۱۶) به‌عنوان مؤثرترین پارامتر در پیش‌بینی پهنه‌های مستعد زمین‌لغزش در حوزه آبخیز جنگلی ۸۵ شناسایی شد. این یافته کاملاً با شرایط زمین‌شناختی منطقه مطابقت دارد، چراکه نزدیکی به گسل‌ها نشان‌دهنده مناطقی با سنگ‌بستر تضعیف‌شده و درهم‌ریخته تحت تأثیر فعالیت‌های تکتونیکی است.

پس از فاصله از گسل، عامل فاصله از رودخانه با اهمیت حدود ۰/۱۴ در رتبه دوم قرار گرفت که نشان‌دهنده تأثیر قابل‌توجه فرسایش کناره‌ای و ناپایداری دامنه‌های مجاور آبراهه‌ها در منطقه است.

## Feature Importance Analysis



شکل ۸- نمودار اهمیت متغیرهای مؤثر در پهنه‌بندی حساسیت زمین‌لغزش حاصل از مدل شبکه عصبی پیچشی (CNN)  
 Fig. 8. Feature importance plot of the factors affecting landslide susceptibility zoning derived from the Convolutional Neural Network (CNN) model

## نتیجه‌گیری

این پژوهش به ارزیابی و مقایسه عملکرد چهار الگوریتم یادگیری ماشین و عمیق در پهنه‌بندی حساسیت زمین‌لغزش در حوزه آبخیز جنگلی ۸۵ پرداخت. مدل CNN با امتیاز AUC برابر ۰/۹۱۰، ضریب کاپای ۰/۸۹۹ و صحت کلی ۸۷/۷۲ درصد عملکرد ممتازی از خود نشان داد. توانایی این مدل در شناسایی مناطق پرخطر، آن را به‌عنوان ابزاری قدرتمند و قابل اعتماد برای برنامه‌ریزی‌های مدیریت ریسک و کاربری اراضی تبدیل می‌کند.

تمرکز بر توسعه و به‌کارگیری این مدل در مطالعات آتی می‌تواند دقت و قابلیت اطمینان پیش‌بینی‌های حساسیت زمین‌لغزش را به میزان قابل توجهی افزایش دهد. تحلیل اهمیت متغیرها نیز حاکی از آن بود که عوامل شیب و فاصله از گسل تأثیرگذارترین پارامترها در وقوع زمین‌لغزش در منطقه مورد مطالعه هستند. علاوه بر این، یافته‌ها حاکی از همخوانی قابل توجه بین اهمیت نسبی عوامل مؤثر بود که نشان‌دهنده سازگاری فنی الگوریتم‌های به‌کاررفته با ماهیت پدیده زمین‌لغزش است.

اگرچه مدل‌های یادگیری عمیق (CNN/RNN) عموماً برای داده‌های حجیم و سری‌های زمانی پیچیده طراحی شده‌اند، اما نتایج این پژوهش نشان داد که حتی با حجم داده‌های محدود این مطالعه، قابلیت فوق‌العاده معماری CNN در استخراج خودکار

ویژگی‌های پیچیده مکانی منجر به دقت بالاتر آن نسبت به مدل‌های کلاسیک یادگیری ماشین (RF و SVM) شده است. این امر پتانسیل بالای این مدل‌ها را برای کاربرد در مطالعات مکانی-محیطی حتی با داده‌های با حجم متوسط نیز تأیید می‌کند. به‌طورکلی، یافته‌های این مطالعه توانایی بالای رویکردهای یادگیری عمیق، به‌ویژه مدل CNN را در تهیه نقشه‌های حساسیت با دقت بالا تأیید می‌کند.

نقشه‌های تولیدشده می‌تواند به‌عنوان یک ابزار علمی معتبر در برنامه‌ریزی کاربری اراضی، طراحی زیرساخت‌ها و اجرای طرح‌های کاهش خطر زمین‌لغزش توسط مدیران و برنامه‌ریزان مورد استفاده قرار گیرد. این پژوهش با وجود دستاوردهای ارزشمند، محدودیت‌هایی دارد که راهکارهای آتی را مشخص می‌کند. در این راستا ضرورت روزآمدسازی دوره‌های داده‌های محیطی و نقاط لغزشی برای حفظ دقت مدل‌ها وجود دارد. علیرغم استفاده از داده‌های نقطه‌ای زمین‌لغزش از مراجع معتبر، محدودیت‌های ذاتی روش‌های مرسوم شناسایی و جمع‌آوری این داده‌ها (مانند مشکل در شناسایی زمین‌لغزش‌های پنهان در پوشش گیاهی انبوه و تعیین مرز دقیق نواحی گسیختگی) می‌تواند بر دقت مدل‌های تولیدی تأثیر بگذارد.

بنابراین، به‌منظور غنی‌سازی و افزایش قابلیت اطمینان داده‌های آموزشی در آینده، استفاده از

### تشکر و قدردانی

نویسندگان مراتب سپاس و قدردانی خود را از اداره کل منابع طبیعی و آبخیزداری استان گلستان به‌ویژه معاونت محترم آبخیزداری این استان که با فراهم آوردن داده‌ها و اطلاعات لازم مسیر انجام این پژوهش را هموار نمودند، اعلام می‌دارند.

### تعارض منافع

در این مقاله تضاد منافی وجود ندارد و این مساله مورد تایید همه نویسندگان است.

فناوری لیدار برای ایجاد یک پایگاه داده مکانی کامل‌تر پیشنهاد می‌شود. این داده‌ها قادر خواهند بود هم عوارض میکروتوپوگرافی مؤثر و هم زمین‌لغزش‌های پنهان را آشکار ساخته و به‌عنوان معیار دقیق‌تری برای آموزش و اعتبارسنجی مدل‌ها مورد استفاده قرار گیرند. همچنین توسعه چارچوب‌های هیبریدی که مدل‌های فیزیکی را با روش‌های داده‌کاوی تلفیق می‌کنند، می‌تواند به بهبود قابلیت تفسیرپذیری نتایج منجر شود. درنهایت، این رویکرد چند الگویی با ارائه هم‌زمان خروجی‌های کمی و کیفی، چارچوبی جامع برای مدیریت ریسک زمین‌لغزش در سطوح مختلف مدیریتی فراهم خواهد آورد.

### منابع مورد استفاده

- Abdelkader, M. M., Csámer, Á., 2025. Comparative assessment of machine learning models for landslide susceptibility mapping: a focus on validation and accuracy. *Nat. Hazards* 1-23.
- Abolfathi, K., Alikhah-Asl, M., Rezvani, M., 2015. Range classification and evaluation using Geographic Information System (GIS) and Normalized Difference Vegetation Index (NDVI), case study: Hablehrood Subwatershed of Shahrabad Basin. *Hum. Environ.* 13, 45-55 (in Persian).
- Alavi, E.S., Dinpashoh, Y., Asadi, E., 2019. Analysis of hourly storms for the purpose of extracting design hyetographs using the Huff method. *Geogr. Environ. Plann.* 30, 41-58 (in Persian).
- Alavinia, M., Nasiri Saleh, F., Asadi, H., 2019. Effects of rainfall patterns on runoff and rainfall-induced erosion. *Int. J. Sediment Res.* 34, 270-278.
- Babar Beig, N., Larestani, Gh., Esmaeili, R., 2025. Landslide susceptibility zonation using random forest and support vector machine models (Case study: Talar watershed). *Earth Sci. Res. J.* 16(1), 152-168 (in Persian).
- Chang, Z., Huang, F., Huang, J., Jiang, S.H., Liu, Y., Meena, S.R., Catani, F., 2023. An update of landslide susceptibility prediction from the perspective of space and time. *Geosci. Frontiers.* 14(5), 101619.
- Custodio, P.M., 2025. Improving MRI classification through layered convolutional neural network configuration. *Smart Techno.* 7(1), 45-58.
- Daviran, M., Shamekhi, M., Ghezlbash, R., Maghsoudi, A., 2023. Landslide susceptibility prediction using artificial neural networks, SVMs, and random forest: Hyperparameters tuning by the genetic optimization algorithm. *Int. J. Environ. Sci. Technol.* 20(1), 259-276.
- Destranj, A., Karimi Sangchini, A., Noor, H., 2024. Evaluation of machine learning models efficiency in preparing landslide hazard map in Bar Neyshabur watershed. *Watershed Manage. Res. J.* 37(2), 133-147 (in Persian).
- Destranj, A., Karimi Sangchini, A., Noor, H., 2024. Landslide risk assessment in Bar Neyshabur watershed, Razavi Khorasan province. *Iran. J. Water. Manage. Sci. Engin.* 18(67), 44-57 (in Persian).
- Ferreira, Z., Almeida, B., Costa, A.C., do Couto Fernandes, M., Cabral, P., 2025. Insights into landslide susceptibility: A comparative evaluation of multi-criteria analysis and machine learning techniques. *Geomatics. Nat. Hazards ad Risk* 16(1), 1-22.
- Fitriana, H.L., Ismanto, R.D., Tulus, J.S., Julzarika, A., Nugroho, J.T., Manalu, J., 2024. Comparison of statistical and machine-learning models for analyzing landslide susceptibility in the Sumedang area, Indonesia. *Geomat. Environ. Engin.* 18(2), 45-62.
- Ganesh, B., Vincent, S., Pathan, S., Benitez, S.R.G., 2023. Machine learning based landslide susceptibility mapping models and GB-SAR-based landslide deformation monitoring systems: Growth and evolution. *Remote Sensing Applications: Soci. Environ.* 29, 100905.
- Géron, A., 2017. Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems. O'Reilly Media, Inc.
- Habumugisha, J.M., Chen, N., Rahman, M., Islam, M.M., Ahmad, H., Elbeltagi, A., Dewan, A., 2022. Landslide susceptibility mapping with deep learning algorithms. *Sustain.* 14(3), 1734.

- Heaton, J., 2020. Applications of deep neural networks with keras. arXiv preprint arXiv:2009.05673.
- Huang, J., Zhang, Z., Ling, S., Chen, K., Shi, G., Zhang, Y., 2025. Landslide susceptibility mapping using advanced ensemble learning techniques integrating a reduced error pruning tree. *Advances in Space Research*.
- Indu, M., Barki, B.G., 2012. A study to integrate the differently abled through technical and vocational education in the polytechnic colleges in the southern region of India. *Asian J. Res. Social Sci. Human*. 2(4), 304-311.
- Javidan, N., Kavyan, A., Rajabi, S., Pourghasemi, H., Jafarian, Z., 2023. Identification of prone areas to gully erosion and landslide in the form of a two-hazard map using machine learning models in Gorganrood watershed. *Iranian J. Water. Manage. Sci. Engin*. 17(62), 75-85 (in Persian).
- Kalantar, B., Pradhan, B., Naghibi, S.A., Motevalli, A., Mansor, S., 2018. Assessment of the effects of training data selection on the landslide susceptibility mapping: A comparison between support vector machine (SVM), logistic regression (LR), and artificial neural networks (ANN). *Geomat. Nat. Hazards Risk* 9(1), 49-69.
- Kleiman, R., Page, D., 2019. Auç: A performance metric for multi-class machine learning models. In *International Conference on Machine Learning* (3439-3447). PMLR.
- Kornejady, A., Ownegh, M., Rahmati, O., Bahremand, A., 2018. Landslide susceptibility assessment using three bivariate models considering the new topo-hydrological factor: HAND. *Geocarto Int*. 33(11), 1155-1185.
- Kornejady, A., Ownegh, M., Pourghasemi, H., Bahremand, A., Motamedi, M., 2020. Landslide susceptibility prediction using hybrid Mahalanobis distance and machine learning models (Case study: Oghan watershed, Golestan province). *Earth Sci. Res. J*. 11(2), 1-18 (in Persian).
- Kumar, S., Lopez, D., 2016. A review on feature selection methods for high-dimensional data. *J. Big Data*. 3(1), 1-25.
- Lokesh, P., Madhesh, C., 2025. Machine learning and deep learning-based landslide susceptibility mapping using geospatial techniques in Wayanad, Kerala state, India. *Hydro Res*. 8, 113-126.
- Lokesh, P., Madhesh, C., Mathew, A., Shekar, P.R., 2025. Machine learning and deep learning-based landslide susceptibility mapping using geospatial techniques in Wayanad, Kerala state, India. *Hydro Res*. 8, 113-126.
- Mastouri, A., Shataee Jouibari, S., Moayeri, M.H., Maghsoudi Mehrani, Y., 2022. Landslide susceptibility mapping using GIS-based MCDM method in Arabdagh forests of Iran. *Environ. Resour. Res*. 10(2), 165-182.
- Melati, D.N., Umbara, R.P., Astisiasari, A., Wisyanto, W., Trisnafiah, S., Trinugroho, T., Anggreainy, M. S., 2024. A comparative evaluation of landslide susceptibility mapping using machine learning-based methods in the Bogor area of Indonesia. *Environ. Earth Sci*. 83(3), 86.
- Mohammadi, M., Jolokhani Neyarki, M., 2023. Preparing landslide susceptibility map using statistical and machine learning models (Case study: Austria country). *Geomat. Sci. Technol*. 13(2), 79-94 (in Persian).
- Mohammadyari, F., Mirsanjari, M., Zardean, A., 2018. Monitoring vegetation changes in Karaj watershed using normalized difference vegetation index and gradient analysis. *Remote Sens. GIS in Nat. Resour*. 9(4), 55-72 (in Persian).
- Norouzi Goshbalag, H., Nadiri, A., 2018. Forecasting the underground water level of Bukan Plain using fuzzy logic, random forest, and neural network models. *Pasture Watershed Quart*. 72(1), 291-306 (in Persian).
- Petley, D., 2012. Global patterns of loss of life from landslides. *Geol*. 40, 927-930.
- Pourghasemi, H.R., Rahmati, O., 2018. Prediction of the landslide susceptibility: Which algorithm, which precision? *Catena* 162, 177-192.
- Pourghasemi, H.R., Pouyan, S., Bordbar, M., Golkar, F., Clague, J.J., 2023. Flood, landslides, forest fire, and earthquake susceptibility maps using machine learning techniques and their combination. *Nat. Hazards*. 116(3), 3797-3816.
- Rafiei Sardooi, E., 2022. Simulating landslide susceptibility with data mining models in Rabor region, Kerman province. *Watershed Manage. Res. J*. 35(2), 101-118 (in Persian).
- Rodriguez, V., Ghimire, B., Rogan, J., Chica-Olmo, M., Rigol-Sánchez, J.P., 2012. An assessment of the effectiveness of a Random Forest classifier for land-cover classification. *ISPRS J. Photogram. Remote Sens*. 67, 93-104.
- Sadeghi, S.H., Mousavi, S.R., Vahabzadeh Kabria, Gh., Roshan, S.H., 2024. Evaluation of random forest and support vector machine models in preparing landslide susceptibility map (Case study: Tajan watershed, Mazandaran province). *Nat. Environ. Hazards* 16(1), 1-15 (in Persian).
- Sepahvand, A., Biranvand, N., 2024. Landslide susceptibility zonation using machine learning algorithms (Study area: part of Haraz watershed). *Water Soil Model Manage*. 4(2), 261-278 (in Persian).

- Sepahvand, A., Sihag, P., Singh, B., Zand, M., 2018. Comparative evaluation of infiltration models. *KSCE J. Civil Engin.* 22(10), 4173-4184.
- Shirani, K., Naderi Samani, R., 2022. Determining effective factors and evaluating landslide susceptibility with random forest and artificial neural network methods in Doab Samsami region of Chaharmahal and Bakhtiari province. *Watershed Manage. Res. J.* 35(1), 40-60 (in Persian).
- Shirani, K., Peyrowan, H.R., Naderi Samani, R., 2024. Applied Principles of Zonation and Prediction of Land Susceptibility to Landslide Occurrence (Using Machine Learning and Programming in MATLAB). Soil Conservation and Watershed Management Research Institute (in Persian).
- Singh, P., Singh, V.P., Angelaki, A., Kumar, V., Sepahvand, A., Golia, E., 2019. Modelling of infiltration using artificial intelligence techniques in semi-arid Iran. *Hydrol. Sci. J.* 64(13), 1647-1658.
- Sun, X., Chen, J., Bao, Y., Han, X., Zhan, J., Peng, W., 2018. Landslide susceptibility mapping using logistic regression analysis along the Jinsha river and its tributaries close to Derong and Deqin County, southwestern China. *ISPRS Int. J. Geo-Inform.* 7(11), 438.
- Taheri, V., Karam, A., Safari, A., Shataee Jouibari, Sh., 2020. Landslide zonation in the mountainous area of Golestan province using hybrid algorithm of least squares support vector machine and artificial bee colony. *Geograph. Space Arrange.* 10(37), 213-230 (in Persian).
- Thammaboribal, P., Triapthi, N.K., Lipiloet, S., 2025. Using of Analytical Hierarchy Process (AHP) in Disaster Management: A Review of Flooding and Landslide Susceptibility Mapping. *Int. J. Geoinform.* 21(4), 177-196.
- Wu, H., Niu, J., Li, Y., Wang, Y., Qiu, D., 2025. Landslide Susceptibility Prediction Based on a CNN-LSTM-SAM-Attention Hybrid Model. *Applied Sci.* 15(13), 7245.
- Yang, K., Zhang, L., Wang, J., Chen, X., 2024. Displacement prediction method for rainfall-induced landslide using improved completely adaptive noise ensemble empirical mode decomposition, singular spectrum analysis, and long short-term memory on time series data. *Water.* 16(15), 2111.
- Zhao, Z., Liu, Z.Y., Xu, C., 2021. Slope unit-based landslide susceptibility mapping using certainty factor, support vector machine, random forest, CF-SVM, and CF-RF models. *Frontiers Earth Sci.* 9, 589630.
- Zhou, C., Yin, K., Cao, Y., Ahmed, B., Li, Y., Catani, F., Pourghasemi, H.R., 2018. Landslide susceptibility modelling applying machine learning methods: A case study from Longju in the Three Gorges Reservoir area, China. *Comput. Geosci.* 112, 23-37.

