



Landslide Susceptibility Modelling Using Artificial Neural Network Algorithm: A Case Study of the Shahid Abbaspour Dam Catchment, Northeastern Khuzestan

Mahshid Moavi ¹, Heeva Elmizadeh ^{2*}, Mojgan Entezari ³

¹ Department of Physical Geography, Faculty of Geographical Sciences and Planning, University of Isfahan, Isfahan, Iran

^{2*} Department of Marine Geology, Faculty of Marine Natural Resources, Khorramshahr University of Marine Science and Technology, Khorramshahr, Iran

³ Department of Physical Geography, Faculty of Geographical Sciences and Planning, University of Isfahan, Isfahan, Iran

ARTICLE INFO

ABSTRACT

Article History:

Received: 26 March 2025

Revised: 09 June 2025

Accepted: 11 June 2025

Available Online: 12 June 2025

Keywords:

Landslide Susceptibility Mapping

Artificial Neural Network (ANN)

Geographic Information System (GIS)

Remote Sensing

Shahid Abbaspour Dam Watershed

Southwest of Iran

Landslides are natural hazards that pose significant risks to human lives and the environment. Landslide susceptibility maps are vital tools for planning, management, and risk-reduction strategies. Various methods exist for generating these maps, but their effectiveness varies across studies. This research aimed to develop a landslide susceptibility map for the Shahid Abbaspour Dam watershed using an Artificial Neural Network (ANN). Landslide data points were randomly split into a 70% training and 30% testing dataset. Fifteen influencing factors were selected as model inputs, including elevation, slope, aspect, curvature, Stream Power Index (SPI), Topographic Wetness Index (TWI), distance to roads and rivers, geology, soil texture, land use, and precipitation. Model validation was performed using accuracy metrics and statistical indices (RMSE, Cohen's Kappa, MAE, and R²). The ANN model demonstrated strong predictive performance, achieving an accuracy of 0.8543. The study identified rivers as the most critical factor influencing landslide susceptibility in the area, followed by slope and geological formations. The highest susceptibility zones were found in the southwest and in a small northern section of the watershed. The resulting map provides valuable support for land-use planning and sustainable development strategies aimed at mitigating landslide risks in the region.

*Corresponding author: Dr. Heeva Elmizadeh

E-mail address: elmizadeh@kmsu.ac.ir

How to cite this article: Moavi, M., Elmizadeh, H., & Entezari, M. (2025). Landslide Susceptibility Modelling Using Artificial Neural Network Algorithm: A Case Study of the Shahid Abbaspour Dam Catchment, Northeastern Khuzestan. *Journal of Geography and Environmental Hazards*, 14(3), 38-54. <https://doi.org/10.22067/geoeH.2025.92634.1557>



©2025 The author(s). This is an open access article distributed under Creative Commons Attribution 4.0 International License (CC BY 4.0)

Extended Abstract

Introduction

Landslides rank among the most destructive natural hazards, endangering human lives, infrastructure, and the natural environment across the globe. In Iran, the northeastern part of Khuzestan Province, including the Shahid Abbaspour Dam watershed, is especially prone to landslides due to its mountainous topography, diverse geological formations, and seasonal rainfall patterns. Landslide susceptibility maps, which estimate the likelihood of occurrence based on local terrain and environmental conditions, are critical tools for planners, engineers, and policymakers. These maps guide land-use decisions, infrastructure development, and disaster preparedness, thereby reducing potential impacts on communities and ecosystems. Various methods, ranging from statistical models to machine learning techniques, have been employed to create such maps, each with varying degrees of accuracy and applicability. However, few studies have applied advanced machine learning approaches, such as Artificial Neural Networks (ANNs), in the Shahid Abbaspour Dam watershed, a critical area within the Greater Karun watershed. This research fills this gap by modeling landslide susceptibility in the region using an ANN, a method known for its ability to handle complex, non-linear relationships among multiple variables. The objective of this study is to produce a reliable susceptibility map to support risk mitigation, land-use planning, and sustainable development in this environmentally sensitive area. By leveraging the ANN's predictive power, this study offers a robust, scientifically grounded approach to addressing a pressing regional challenge, contributing to the broader field of geohazard assessment.

Material and Methods

The study focuses on the Shahid Abbaspour Dam watershed, located in northeastern Khuzestan. This area, part of the Greater Karun watershed, features rugged terrain, diverse geology, and a history of landslide activity, making it ideal for susceptibility analysis. Our methodology was conducted in five comprehensive stages to assess the probability of landslides based on local conditions. First, we conducted an extensive literature review to identify relevant factors and gathered data from multiple sources. Second, we selected and prepared 15 influencing factors as spatial layers: elevation, slope gradient, slope aspect, curvature, Stream Power Index (SPI), Topographic Wetness Index (TWI), distance from roads, distance from rivers, proximity to faults, geological formations, soil texture, land-use patterns, precipitation, Normalized Difference Vegetation Index (NDVI), and seismic activity. These datasets were derived from 1:50,000-scale topographic maps, 1:100,000-scale geological maps, and a 30-meter resolution Digital Elevation Model (DEM) from ASTER satellite imagery. In the third stage, we implemented an Artificial Neural Network (ANN) in the R programming environment using the *nnet* package. This machine learning approach excels at capturing non-linear patterns among variables, making it suitable for landslide prediction. The ANN was configured with a single hidden layer of 10 neurons, trained with 70% of the dataset, and tested with the remaining 30%. The fourth stage involved generating a landslide susceptibility map, classifying the area into zones of varying risk. Finally, we validated the model using a suite of performance metrics: accuracy, Root Mean Square Error (RMSE), Kappa coefficient, Mean Absolute Error (MAE), R-squared value, sensitivity, specificity, Positive Predictive Value (PPV), and Negative Predictive Value (NPV). These metrics ensured a robust evaluation of the model's predictive accuracy and reliability, in line with best practices in geohazard modeling.

Results and Discussion

The Artificial Neural Network (ANN) model demonstrated strong predictive performance, achieving an accuracy of 0.8543, RMSE of 0.123, Kappa coefficient of 0.79, MAE of 0.098, and R-squared value of 0.9916. These metrics confirm the model's reliability in mapping landslide susceptibility across the Shahid Abbaspour Dam watershed. Analysis revealed three primary factors driving landslide risk in the area. Proximity to rivers emerged as the most influential, likely due to mechanisms such as bank erosion, increased soil moisture, and fluctuating groundwater levels. This finding aligns with Zakerinejad and

Amoshahi (2022), who noted heightened risk within 100 meters of watercourses in similar regions. Slope gradient ranked as the second key factor, with steep slopes, particularly in the southwestern Dezful region, amplifying instability. Geological formations, especially the erosion-prone Gachsaran Formation and Quaternary alluvial deposits rich in marl, ranked third, underscoring their role in susceptibility. This observation echoes Mohammadi et al. (2022), who studied the Izeh and Deh Sheikh (Abbaspour Dam) basins. In contrast, elevation and slope curvature showed limited influence, differing from Selamat et al. (2022), where elevation was a primary factor, possibly due to the unique topographic and geologic traits of our study area. Other factors, such as NDVI and seismic activity, had moderate to minor roles, likely reflecting stable vegetation cover and low seismicity. The susceptibility map classified 31.3% of the area (75.37 km²) as high-risk zones, concentrated in the southwest and a small northern section. Sensitivity analysis across susceptibility classes showed consistent performance, with values ranging from 0.8060 for the lowest class to 0.8717 for the high-susceptibility class. These results highlight the ANN's effectiveness and its alignment with regional patterns, offering a reliable tool for understanding landslide dynamics in the watershed.

Conclusion

This study successfully developed a landslide susceptibility map for the Shahid Abbaspour Dam watershed using an Artificial Neural Network, identifying key factors and high-risk zones. Proximity to rivers, slope gradient, and geological formations, particularly the Gachsaran Formation and Quaternary alluvium, emerged as the primary drivers of landslide risk. High-susceptibility zones, covering 31.3% of the area, were predominantly located in the southwestern and northern parts, providing critical insights for targeted interventions. The ANN model performed robustly, with an accuracy of 0.8543, RMSE of 0.123, Kappa of 0.79, MAE of 0.098, and R-squared of 0.9916, validating its predictive power. These metrics underscore the model's reliability and its potential for application in similar watersheds prone to landslides. By quantifying the influence of environmental and terrain factors, this research offers a scientific foundation for land-use planning, infrastructure design, and disaster risk management in northeastern Khuzestan. The findings can guide policymakers and planners in prioritizing mitigation efforts, such as stabilizing slopes near rivers, regulating development on steep terrain, and monitoring vulnerable geological units. Future studies could refine this model by incorporating real-time data, such as rainfall forecasts or seismic monitoring, to enhance predictive accuracy and adaptability.



مدل سازی حساسیت زمین لغزش با استفاده از الگوریتم شبکه عصبی مصنوعی (مطالعه موردی: حوضه آبریز سد شهید عباسپور، شمال شرق خوزستان)

مehشید معاوی^۱، هیوا علمی زاده^{۲*}، مژگان انتظاری^۳

^۱ دانشجوی دکتری، گروه جغرافیای طبیعی، دانشکده علوم جغرافیایی و برنامه ریزی، دانشگاه اصفهان، اصفهان، ایران
^{۲*} دانشیار، گروه زمین شناسی دریایی، دانشکده منابع طبیعی دریا، دانشگاه خرمشهر، خرمشهر، ایران
^۳ دانشیار، گروه جغرافیای طبیعی، دانشکده علوم جغرافیایی و برنامه ریزی، دانشگاه اصفهان، اصفهان، ایران

چکیده	اطلاعات مقاله
	تاریخچه مقاله:
	تاریخ دریافت: ۱۴۰۴/۰۱/۰۶
	تاریخ بازنگری: ۱۴۰۴/۰۳/۱۹
	تاریخ پذیرش: ۱۴۰۴/۰۳/۲۱
	کلمات کلیدی:
	نقشه حساسیت زمین لغزش
	شبکه عصبی مصنوعی (ANN)
	سیستم اطلاعات جغرافیایی (GIS)
	سنجش از دور
	حوضه آبریز سد شهید عباسپور
	جنوبغرب ایران
زمین لغزشها به عنوان یکی از مهم ترین مخاطرات طبیعی می توانند خسارات شدیدی به بار آورند. در این زمینه، تهیه نقشه های حساسیت زمین لغزش برای برنامه ریزی، مدیریت و پیشگیری از وقوع این پدیده و در نتیجه کاهش خسارات ناشی از آن، از اهمیت ویژه ای برخوردار است. هدف اصلی این پژوهش، تهیه نقشه حساسیت زمین لغزش برای حوضه سد شهید عباسپور با استفاده از روش شبکه عصبی مصنوعی (NNET) است. در این مطالعه، داده های مربوط به نقاط زمین لغزش به صورت تصادفی و با نسبت ۷۰ به ۳۰ بین داده های آموزشی و داده های آزمون تقسیم شدند. در ادامه پانزده عامل مؤثر بر زمین لغزش شامل عوامل توپوگرافیک (ارتفاع، شیب، جهت شیب و انحنای دامنه)، شاخص های هیدرولوژیک (SPI) و شاخص رطوبت توپوگرافی (TWI)، عوامل انسانی (فاصله از جاده) و ویژگی های طبیعی (فاصله از رودخانه، زمین شناسی، بافت خاک، کاربری اراضی و بارش) مورد بررسی قرار گرفتند. برای اعتبارسنجی مدل پیش بینی زمین لغزش، از معیارهای مختلفی شامل Accuracy و شاخص های آماری RMSE، Kappa، MAE و R-Squared استفاده شده است. نتایج حاصل از این ارزیابی ها نشان داد که مدل NNET از عملکرد خوبی با دقت ۰/۸۵۴۳ برخوردار است. یافته های پژوهش حاکی از آن است که در حوضه سد شهید عباسپور، نزدیکی به رودخانه به عنوان مهم ترین عامل مؤثر در حساسیت زمین لغزش شناسایی شده است. پس از این عامل، شیب دامنه و ویژگی های زمین شناسی در رتبه های بعدی اهمیت قرار دارند. همچنین نتایج نشان می دهد که مناطقی که بیشترین حساسیت به زمین لغزش را دارا هستند عمدتاً در بخش های جنوب غربی و قسمت هایی از شمال حوضه واقع شده اند. نقشه حساسیت زمین لغزش تهیه شده در این تحقیق، می تواند به عنوان ابزاری ارزشمند در برنامه ریزی های توسعه ای، مدیریت ریسک و پیشگیری از	

خسارات ناشی از زمین لغزش در منطقه مورد مطالعه، مورد استفاده قرار گیرد. این یافته‌ها، به مدیران و برنامه‌ریزان کمک می‌کند تا تصمیم‌گیری‌های مناسب‌تری در زمینه توسعه منطقه اتخاذ نمایند.

مقدمه

زمین لغزش به‌عنوان یکی از مهم‌ترین مخاطرات طبیعی، سالانه خسارات جانی و مالی قابل توجهی در سراسر جهان ایجاد می‌کند (Sun et al., 2020; Bao et al., 2020). این پدیده زمین‌شناسی که به حرکت رو به پایین توده‌های خاک و سنگ در امتداد دامنه‌های شیب‌دار اطلاق می‌شود (Hung, Leroueil & Picarelli, 2024)، می‌تواند به اشکال مختلفی از جمله سقوط، واژگونی، لغزش دورانی، لغزش انتقالی، گسترش جانبی و جریان رخ دهد. سرعت این حرکات نیز از کند تا بسیار سریع، متغیر است. عوامل متعددی در وقوع زمین لغزش نقش دارند که مهم‌ترین آنها شامل ویژگی‌های خاک و سنگ بستر، شرایط توپوگرافی، عوامل هیدرولوژیکی و فعالیت‌های انسانی می‌شود (Mohammadi, Shahabi & Bin Ahmad, 2018). این تنوع عوامل و پیچیدگی روابط بین آنها، توسعه مدل‌های پیش‌بینی دقیق را با چالش‌های جدی، مواجه کرده است. در این میان، کیفیت داده‌های ورودی و روش‌شناسی مدل سازی از تعیین‌کننده‌ترین عوامل در دستیابی به نتایج قابل اعتماد هستند (Hung et al., 2024).

ارزیابی خطر زمین لغزش به دو دسته کیفی و کمی تقسیم می‌شود. روش‌های کیفی مانند: تحلیل توزیعی، تحلیل ژئومورفیک و ارزیابی خبره، عمدتاً بر اساس تجربه و تخصص کارشناسان انجام می‌گیرد. در مقابل، روش‌های کمی با استفاده از تحلیل‌های عددی و آماری، امکان پیش‌بینی دقیق‌تری را فراهم می‌کنند (Hung et al., 2024; Selamat, Majid, Taha & Osman, 2022). نقشه‌برداری حساسیت زمین لغزش (LSM) به‌عنوان یکی از مؤثرترین ابزارهای مدیریت ریسک، با تحلیل تاریخی عوامل ژئومحیطی مؤثر در وقوع زمین لغزش‌های گذشته، امکان پیش‌بینی مناطق مستعد را فراهم می‌کند. در سال‌های اخیر، مدل‌های یادگیری ماشین مانند شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM)، نایو بیز (NB)، درخت تصمیم (DT) و جنگل تصادفی (RF) به دلیل توانایی در کشف روابط غیرخطی بین عوامل مؤثر، نتایج امیدبخشی در این زمینه ارائه داده‌اند (Selamat et al., 2022).

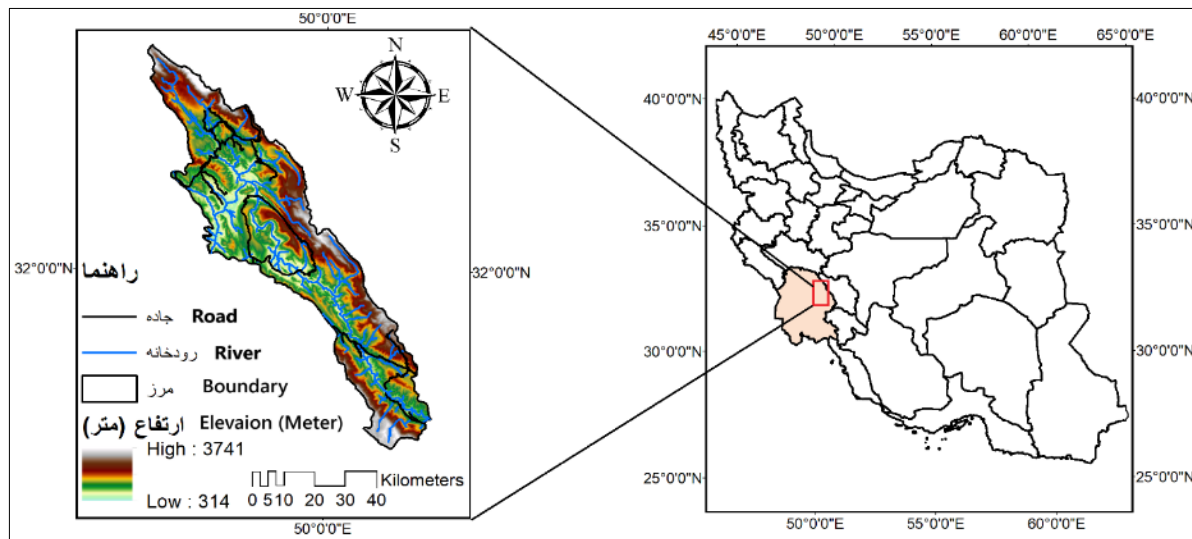
منطقه مورد مطالعه این تحقیق، در حوضه آبریز سد شهید عباسپور واقع در شمال شرق استان خوزستان قرار دارد. ویژگی‌های منحصر به فرد این منطقه از جمله قرارگیری در کمربند چین‌خورده زاگرس، وجود گسل‌های فعال، شبکه زهکشی فصلی و دریاچه سد کارون ۳، آن را به منطقه‌ای بسیار مستعد برای وقوع زمین لغزش تبدیل کرده است (Ghaedi, Amouzegar & Shojaiean, 2022; Mohammadi, Afifi & Ghanbari, 2023). با توجه به تأثیرات مخرب زمین لغزش‌ها بر پایداری دامنه‌ها، اراضی کشاورزی و توسعه مناطق شهری و روستایی، انجام مطالعات دقیق در این زمینه از ضرورت بالایی برخوردار است. این تحقیق به‌عنوان نخستین مطالعه جامع در زمینه مدل‌سازی حساسیت زمین لغزش با استفاده از الگوریتم NNET در حوضه آبریز سد شهید عباسپور، می‌تواند مبنای علمی ارزشمندی برای برنامه‌ریزی‌های آینده و کاهش مخاطرات طبیعی در این منطقه فراهم کند.

پژوهشگران ایرانی متعددی از روش‌های یادگیری ماشین برای مدل‌سازی حساسیت زمین لغزش استفاده کرده‌اند. حجازی و همکاران (Hejazi, Rezaeimoghadam & Naseri, 2020) در مطالعه‌ای پیشگامانه در پایین دست سد سنندج، از ترکیب مدل شبکه عصبی مصنوعی (ANN) و روش تاپسیس برای پهنه‌بندی خطر زمین لغزش استفاده کردند. در این پژوهش که با استفاده از نرم‌افزار ArcGIS و زبان برنامه‌نویسی پایتون انجام شد، از ۹ لایه اطلاعاتی شامل عوامل مؤثر در زمین لغزش استفاده گردید. ساختار شبکه عصبی به کار رفته شامل: ۹ نورون در لایه ورودی، ۳۰ نورون در لایه پنهان و ۱ نورون در لایه خروجی بود که با الگوریتم یادگیری Adam آموزش دید. نتایج نشان داد مدل ANN با خطای کمتر و انطباق بهتر با شرایط منطقه، عملکرد مطلوب‌تری نسبت به روش تاپسیس دارد. در مطالعه دیگری، اسفندیاری درآبادی و همکاران (Esfandiary Darabad, Rahimi, Navidfar & Arsalan, 2020) به ارزیابی حساسیت زمین لغزش در محور ارتباطی حیران- اردبیل پرداختند. این پژوهش با استفاده از مدل‌های ANN و SVM انجام شد و عوامل مؤثر شامل زمین‌شناسی، ارتفاع، جهت شیب و کاربری اراضی را شناسایی کرد. یافته‌ها نشان داد که مدل SVM در این

منطقه خاص، عملکرد بهتری داشته است. همچنین مشخص شد که اراضی مرتعی، کشاورزی و جاده‌های بالای ۱۴۰۰ متر در غرب گردنه حیران بیشترین حساسیت را به زمین‌لغزش دارند. رجیبی و همکاران (Rajabi, Rezaeimoghadam & Takzare, 2020) در حوضه آبریز الموت رود استان قزوین از مدل ANN برای پهنه‌بندی خطر زمین‌لغزش استفاده کردند. نتایج نشان داد که به ترتیب ۲۶.۸۴٪، ۳۱.۳۶٪، ۲۱.۳۲٪، ۱۶.۹۱٪ و ۳.۴۹٪ از منطقه در کلاس‌های خطر خیلی کم تا خیلی زیاد قرار دارند. مطالعه پلائی و شادفر (Talaei & Shadfar, 2023) در حوضه سفزچای استان اردبیل نشان داد که مدل ANN در مقایسه با رگرسیون لجستیک از دقت بالاتری برخوردار است. در این پژوهش، میانگین بارندگی سالانه و بیشینه شتاب افقی زمین به‌عنوان مهم‌ترین عوامل پیش‌بینی کننده لغزش شناسایی شدند. صادقی بلوچی و علیان (Sadeghi Balochi & Alian, 2025) نیز در شهرستان لاهیجان از مدل ANN برای ارزیابی خطر زمین‌لغزش استفاده کردند. نتایج پهنه‌بندی نشان داد که مدل ANN در این منطقه عملکرد مناسبی داشته است. در سطح جهانی، پژوهشگران متعددی از روش‌های پیشرفته یادگیری ماشین برای مدلسازی حساسیت زمین‌لغزش استفاده کرده‌اند. سلامت و همکاران (Selamat et al., 2022) در مطالعه‌ای بر روی حوضه رودخانه لانگات در مالزی، از شبکه عصبی مصنوعی (ANN) برای تولید نقشه حساسیت زمین‌لغزش استفاده کردند. این پژوهش به نتایج قابل توجهی با مقدار AUC معادل ۰.۹۴۰ برای هر دو مجموعه داده آموزش و آزمون دست یافت. تحلیل عوامل مؤثر نشان داد که بارندگی (با وزن ۰/۲۴۸)، فاصله تا جاده (۰/۲) و ارتفاع (۰/۱۳۶) به ترتیب مهم‌ترین عوامل تأثیرگذار در این منطقه هستند. مسروح و همکاران (Masruroh, Leksono & Kurniawan, 2023) در منطقه برومو تنگر سمرو اندونزی، رویکردی ترکیبی شامل تصاویر ماهواره‌ای سنتینل، عکس‌های هوایی برداشت شده با پهپاد و الگوریتم ANN را به کار گرفتند. نتایج این مطالعه نشان داد که ۲۹٪ از منطقه در کلاس حساسیت پایین، ۳٪ در حساسیت متوسط، ۲٪ در حساسیت بالا و ۱۵٪ در حساسیت بسیار بالا قرار دارد. تحلیل عوامل مؤثر نشان داد که توپوگرافی مهم‌ترین عامل بوده و پس از آن عوامل هیدرولوژیکی و ویژگی‌های سطحی قرار دارند. سان و همکاران (Sun et al., 2022) در مطالعه‌ای جامع به مقایسه عملکرد الگوریتم‌های ANN و جنگل تصادفی (RF) پرداختند. این پژوهش با ایجاد پایگاه داده‌ای شامل ۲۲ عامل مؤثر و ۸۶۶ زمین‌لغزش تاریخی و استفاده از الگوریتم SHAP برای تفسیر نتایج، نشان داد که مدل RF از پایداری و استحکام بیشتری برخوردار است. یافته‌های این مطالعه حاکی از آن است که عوامل مشابه ممکن است در مدل‌های مختلف نقش‌های متفاوتی ایفا کنند. ما و همکاران (Ma, Chen, Wu & Li, 2023) در حوضه دریاچه یینگهوشان، از سه الگوریتم K-means، RF و ANN برای پیش‌بینی حساسیت زمین‌لغزش استفاده کردند. این مطالعه که بر اساس ۱۲ عامل شرطی انجام شد، نشان داد که مدل‌های RF و ANN عملکرد بهتری دارند، با این حال RF از قابلیت پیش‌بینی بالاتری برخوردار بود. همچنین نتایج نشان داد که تعداد زمین‌لغزش‌های ثبت شده بر قابلیت اطمینان نتایج تأثیر مستقیم دارد. بنمخلوف و همکاران (Benmakhlof, El Kharim, Galindo, 2023) در زنجیره ریف بیرونی غربی، سه الگوریتم RF، XGBoost و KNN را مورد مقایسه قرار دادند. یافته‌های این پژوهش نشان داد که RF با مقدار AUC معادل ۰/۸۶ بهترین عملکرد را داشته است. در این مطالعه، شیب، بارندگی و ارتفاع به‌عنوان مهم‌ترین عوامل شناسایی شدند، در حالی که شاخص‌های TWI و SPI کمترین تأثیر را داشتند. با توجه به تجربیات موفق پژوهشگران بین‌المللی و نتایج ارزشمند حاصل از کاربرد روش‌های یادگیری ماشین در مدلسازی زمین‌لغزش، این پژوهش با به‌کارگیری رویکرد شبکه عصبی مصنوعی به بررسی حساسیت زمین‌لغزش در حوضه آبریز سد شهید عباسپور می‌پردازد. انتخاب این روش بر اساس مزایای متعدد آن از جمله توانایی در مدلسازی روابط غیرخطی و پیچیده بین عوامل مؤثر در وقوع زمین‌لغزش صورت گرفته است.

منطقه مورد مطالعه

حوضه آبریز سد شهید عباسپور بخش مهمی از حوضه آبریز کارون بزرگ با مختصات جغرافیایی ۲۳-۴۹° تا ۲۱-۵۰° طول شرقی و ۲۶-۳۱° تا ۳۹-۳۲° عرض شمالی در شمال شرق استان خوزستان را تشکیل می‌دهد (Ali Bakhshi, Azizi, Vafaiejad & Aghamohammadi Zanjirabadi, 2020). محدوده مورد مطالعه از بلندی‌های کوه کینو در شمال سد، شروع شده و تا محل تلاقی رودخانه خرسان با شاخه اصلی کارون در جنوب شرقی امتداد می‌یابد. سیستم آبی منطقه شامل دریاچه سد شهید عباسپور به‌عنوان هسته مرکزی و مسیل‌های مهمی مانند آب سرحوض، آب شلا و آب الگی است که جریان‌های آب مناطق شمال غرب و جنوب شرق را به دریاچه یا شاخه اصلی کارون هدایت می‌کنند (Geological and Mineral Exploration Organization of Iran, 2018). منطقه مورد مطالعه دارای توپوگرافی کوهستانی با شیب‌های تند و دره‌های عمیق است. این شرایط خاص توپوگرافیک همراه با سیستم زهکشی متراکم و ساختار زمین‌شناسی ویژه، منطقه را به محیطی مستعد برای وقوع زمین لغزش تبدیل کرده است. قرارگیری در زون زاگرس چین خورده و وجود سازندهای حساس به فرسایش، از دیگر ویژگی‌های مهم زمین‌شناسی این محدوده محسوب می‌شوند (Majd-bavi & Mumipour, 2022) (شکل ۱).



شکل ۱- نقشه منطقه مورد مطالعه

Fig. 1. Study Area map

مواد و روش‌ها

این پژوهش در پنج مرحله اصلی انجام شد: (۱) بررسی پیشینه تحقیق و جمع‌آوری داده‌ها، (۲) تهیه لایه‌های اطلاعاتی، (۳) اجرای مدل شبکه عصبی، (۴) تهیه نقش پهنه‌بندی حساسیت زمین لغزش، (۵) اعتبارسنجی مدل. در این مطالعه، ۱۵ عامل مؤثر در زمین لغزش شامل ارتفاع، شیب، جهت شیب، فاصله از گسل، فاصله از جاده، فاصله از آبراهه، سازندهای زمین‌شناسی، کاربری اراضی، NDVI، بافت خاک، زلزله، انحنا، دامنه، TWI، SPI، رابطه (۱) و بارش مورد بررسی قرار گرفتند. تمامی لایه‌های اطلاعاتی در محیط نرم‌افزار Arc GIS 10.8 تهیه شدند. در این راستا از داده‌های پایه، شامل نقشه توپوگرافی ۱:۵۰۰۰۰ و نقشه زمین‌شناسی ۱:۱۰۰۰۰۰ محدوده مورد مطالعه و مدل رقومی ارتفاع (DEM) سنجنده ASTER با قدرت تفکیک ۳۰ متر استفاده شد. پارامترهای شیب، جهت شیب، SPI و انحنا دامنه با استفاده از DEM منطقه، استخراج گردیدند. شاخص TWI با استفاده از رابطه (۲) در محیط نرم‌افزار SAGA-GIS 9.0.1 محاسبه شد.

نقشه سازندهای زمین‌شناسی از نقشه ۱:۱۰۰۰۰۰ استان خوزستان تهیه و در محیط ArcMap 10.8 رقومی و به فرمت رستری تبدیل شد. نقشه فاصله از رودخانه با استفاده از ابزارهای هیدرولوژی و فاصله اقلیدسی در ArcGIS تولید گردید. داده‌های کاربری اراضی و بافت خاک به ترتیب از سازمان جهاد کشاورزی و سازمان منابع طبیعی استان خوزستان اخذ شدند. همچنین داده‌های بارش ۲۰ ساله (۱۳۸۲-۱۴۰۲) از ایستگاه‌های باران‌سنجی منطقه با روش درون‌یابی کریجینگ تحلیل شدند. شاخص NDVI نیز با استفاده از تصاویر ماهواره‌ای لندست ۹ و رابطه (۳) در نرم‌افزار ENVI 5.6 محاسبه گردید.

$$SPI = A_s \tan \beta \quad (1)$$

که در آن؛ A_s : سطح ویژه حوضه و β : درجه شیب است. برای تهیه این شاخص از مدل رقومی ارتفاع (DEM) در نرم‌افزار ArcMap 10.8 استفاده گردید.

$$TWI = \ln (A_s / (\tan(\beta))) \quad (2)$$

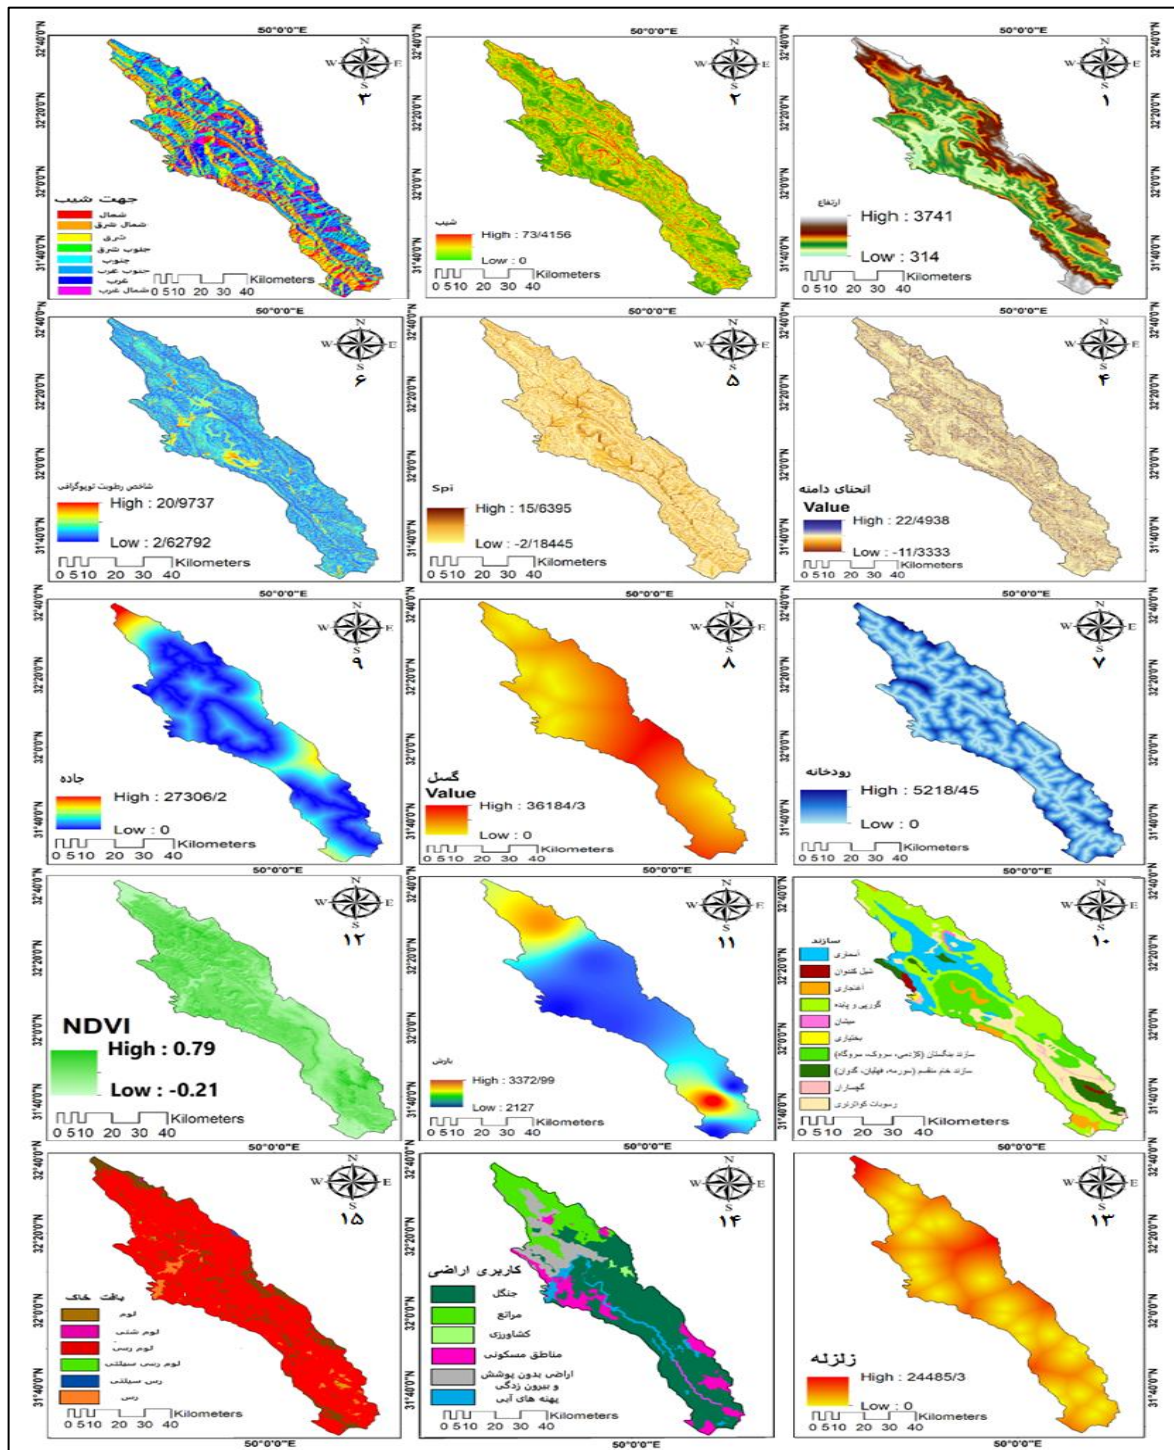
که در آن؛ A_s : سطح ویژه حوضه بر حسب مساحت تجمعی بالادست (مساحت بالادست در واحد طول خط تراز)، β : درجه شیب است که گرایش آب را به جمع شدن در هر نقطه از حوضه (بر حسب A_s) و تمایل نیروهای گرانشی را به انتقال آب پایین دست (بر حسب $\tan \beta$ به‌عنوان شیب هیدرولیکی تقریبی) توصیف می‌کند (Sadati, Mousavi, Vahabzadeh Kebria & Roshun, 2025).

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)} \quad (3)$$

که در آن؛ NIR، بازتاب در باند مادون قرمز نزدیک و RED بازتاب در باند قرمز است. این شاخص در محدوده -۱ تا +۱ بوده، ولی در عمل کمتر از ۱ و بیشتر از -۱ می‌باشد. مقادیر این شاخص برای پوشش گیاهی متراکم به سوی عدد یک، ابرها، برف و آب با مقادیر منفی و سنگ‌ها و خاک‌های بایر با مقادیر نزدیک به صفر دیده می‌شوند (Tayebi far, 2024). مطالعه حاضر، با استفاده از ترکیبی از منابع مختلف شامل نقشه‌های زمین‌لغزش اداره کل منابع طبیعی استان خوزستان، بازدیدهای میدانی گسترده و تفسیر تصاویر ماهواره‌ای Google Earth موفق به شناسایی ۱۲۹ نقطه زمین‌لغزش در حوضه آبریز مورد مطالعه قرار گرفت. این داده‌ها در قالب نقشه پراکنش زمین‌لغزش‌ها تهیه و مورد استفاده قرار گرفتند (شکل ۳). در مرحله آماده‌سازی داده‌ها برای مدل‌سازی و تحلیل‌های آماری، ۲۵۰۰ نقطه به صورت تصادفی در محیط نرم‌افزار Rstudio استخراج شد. این نقاط به دو گروه آموزشی (شامل ۱۹۷۴ پیکسل: ۷۰٪ داده‌ها) و گروه اعتبارسنجی (شامل ۶۵۵ پیکسل: ۳۰٪ داده‌ها) تقسیم شدند (Mostofi, 2013; Tayebi far, 2024; Mousavi Nadushan, 2012). در مرحله پیاده‌سازی الگوریتم شبکه عصبی مصنوعی، از مدل NNET با معماری تک لایه پنهان، استفاده شد که ویژگی‌های کلیدی مانند توانایی مدل‌سازی روابط غیرخطی پیچیده، استفاده از ۱۵ عامل تأثیرگذار در زمین‌لغزش، بهینه‌سازی وزن‌های اتصالات بین نورون‌ها و قابلیت پیش‌بینی احتمال وقوع زمین‌لغزش را دارا می‌باشد (Rahaman, Dondapati, Gupta & Raj, 2024). جهت ارزیابی و اعتبارسنجی مدل از مجموعه‌ای جامع از معیارهای ارزیابی شامل شاخص‌های طبقه‌بندی (Sensitivity, Specificity, PPV, NPV)، معیارهای کمی (Accuracy, RMSE, MAE, R-Squared) و شاخص Kappa (برای ارزیابی توافق پیش‌بینی‌ها) استفاده شد (جدول ۱). این روش‌شناسی جامع، امکان شناسایی دقیق مناطق پرخطر و مدیریت کارآمد ریسک زمین‌لغزش را در منطقه مورد مطالعه، فراهم کرده است. در نهایت نتایج حاصل از این تحلیل‌ها در جداول و نمودارهای مربوطه ارائه شده‌اند.

۱. داده‌های نقاط زمین لغزشی اصلی و تصادفی.

۲. داده‌های تاریخی و برداشت شده از Google Earth، به‌عنوان نقاط نمونه مثبت زمین لغزش استفاده شده، در حالی که نقاط غیر لغزشی، به‌عنوان نقاط نمونه منفی تعیین شده و پایگاه داده مدل را تشکیل می‌دهند.



شکل ۲- به ترتیب نقشه های پارامتر ۱: ارتفاع ۲: شیب ۳: جهت شیب ۴: انحنا دامنه ۵: SPI ۶: TWI ۷: رودخانه ۸: گسل ۹: جاده ۱۰: زلزله ۱۱: بارش ۱۲: NDVI ۱۳: سازندهای زمین شناسی ۱۴: کاربری اراضی ۱۵: بافت خاک

Fig. 2. Maps of parameters, in order: 1. Elevation, 2. Slope, 3. Aspect, 4. Slope curvature, 5. SPI, 6. TWI, 7. Streams, 8. Faults, 9. Roads, 10. Seismic activity, 11. Precipitation, 12. NDVI, 13. Geological formations, 14. Land use, 15. Soil texture


جدول ۱- معیارهای ارزیابی کلاس‌های حساسیت زمین لغزش و اعتبارسنجی الگوریتم شبکه عصبی

Table 1- Evaluation criteria of landslide susceptibility classes and validation of the ANN (Wahba et al., 2024)

نماد Symbol	نماد Symbol	فرمول محاسبه Calculation Formula	رابطه
Sensitivity	حساسیت	$\frac{TP}{TP + FN}$	رابطه (۴)
Specificity	ویژگی	$\frac{TN}{TN + FP}$	رابطه (۵)
Positive Predictive Value (PPV)	ارزش پیش بینی مثبت	$\frac{TP}{FP + TP}$	رابطه (۶)
Negative Predictive Value (NPV)	ارزش پیش بینی منفی	$\frac{TN}{FN + TN}$	رابطه (۷)
Prevalence	فراوانی	$\frac{TP}{TP + FN}$	رابطه (۸)
Accuracy	دقت کلی	$\frac{TP + TN}{TP + FN + FP + TN}$	رابطه (۹)
Kappa	ضریب کاپا	$\frac{PO - Pc}{1 - Pc} * 100$	رابطه (۱۰)
RMSE	ریشه میانگین مربعات خطا	$\frac{1}{N} \sum_{i=1}^n [x_i - x]^2$	رابطه (۱۱)
MAE	میانگین خطای مطلق	$\frac{1}{n} \sum_{i=1}^n [x_i - x]$	رابطه (۱۲)
R-Squared	ضریب تعیین	$1 - \frac{SSE}{SST} = \frac{\sum(Y - Y_1)^2}{\sum(Y - Y)^2}$	رابطه (۱۳)

نتایج و بحث

بر اساس نتایج پژوهش در منطقه مورد مطالعه، رودخانه، شیب و سازندهای زمین‌شناسی به ترتیب تأثیرگذارترین عوامل در حساسیت زمین لغزش شناسایی شدند. فاصله از رودخانه به‌عنوان مهم‌ترین عامل تعیین‌گرید که با فرسایش پای دامنه‌ها، افزایش رطوبت خاک و تغییرات سطح آب زیرزمینی، پایداری شیب‌ها را کاهش می‌دهد. این یافته با نتایج ذاکری‌نژاد و عموشاهی (Zakerinejad & Amoshahi, 2022) که فاصله از آبراهه را مهم‌ترین عامل دانسته‌اند، همخوانی دارد. همچنین پارامتر شیب به‌عنوان دومین عامل مؤثر شناسایی شد. بخش جنوب‌غربی حوضه (دهدز) به دلیل ویژگی‌های کوهستانی و شیب‌های تند، حساسیت بالایی نشان داد. این نتیجه با یافته‌های قائدی و همکاران (Ghaedi et al., 2022)، هه و همکاران (He et al., 2019) و پلوک و همکاران (Pollock, Grant, Wartman & Abou-Jaoude, 2019) مطابقت دارد. سومین عامل حساسیت زمین لغزش، سازندهای زمین‌شناسی محاسبه گردید. آبرفت‌های نرم و فرسایش‌پذیر کواترنری و سازند گچساران به دلیل وجود مارن، منطقه را مستعد لغزش کرده‌اند. در مقابل، شاخص‌های ارتفاع و انحنای دامنه کمترین تأثیر را داشتند. این نتیجه با پژوهش محمدی و همکاران (Mohammadi et al., 2023) درباره حوضه‌های ایذه و ده شیخ همخوانی دارد.



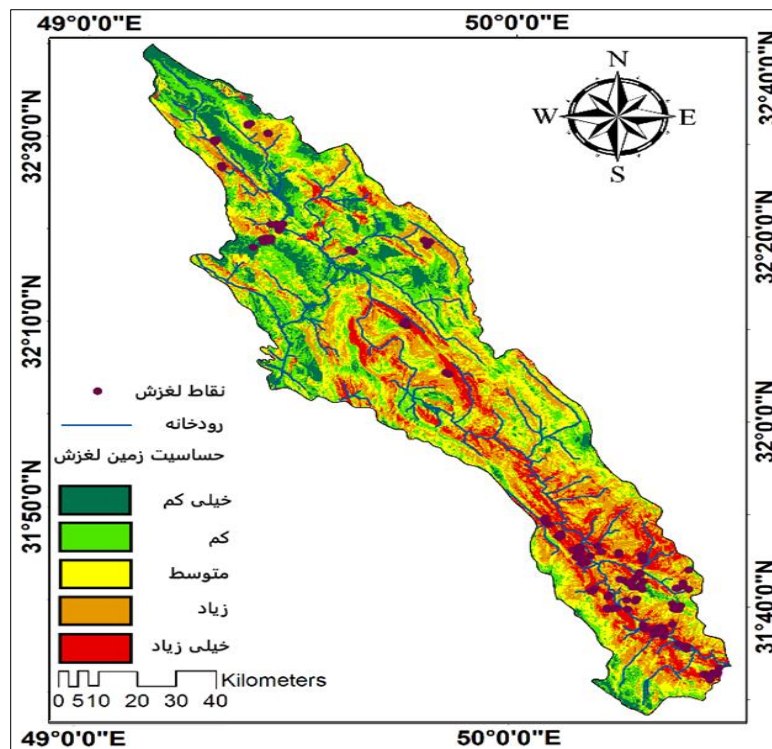
شکل ۳- اهمیت شاخص‌ها در حساسیت زمین لغزش محدوده مورد مطالعه
Fig. 3. Importance of indicators for landslide susceptibility in the study area

بررسی‌های میدانی در منطقه مورد مطالعه، نشان‌دهنده وقوع زمین لغزش در روستاهای زیرکوه شالو، ابوک، دوروه، میراحمد و آب گنجشکی بوده است. مشاهدات حاکی از تأثیر فعالیت‌های انسانی مختلف از جمله سدسازی، تغییر سیستم زهکشی، جاده‌سازی، ساخت‌وساز در دامنه‌ها و تونل‌سازی در افزایش حساسیت منطقه به زمین لغزش می‌باشد (شکل ۴). این عوامل با ایجاد تغییر در شرایط طبیعی شیب‌ها و الگوهای زهکشی، پایداری دامنه‌ها را تحت تأثیر قرار داده‌اند.



شکل ۴- عوامل تأثیرگذار در حساسیت زمین لغزش
Fig. 4. Influencing factors for landslide susceptibility

حساسیت زمین لغزش نشان‌دهنده پتانسیل وقوع این پدیده در مناطق مختلف است که عمدتاً از طریق تهیه نقشه‌های پهنه‌بندی نمایش داده می‌شود. در این مطالعه، نقشه حساسیت زمین لغزش با استفاده از روش شکست طبیعی به پنج کلاس تقسیم‌بندی شده است. این طبقه‌بندی به صورت گرافیکی در شکل ۵ ارائه شده است. نقشه مذکور امکان شناسایی مناطق پرخطر و برنامه‌ریزی برای مدیریت ریسک را فراهم می‌کند. هر کلاس نشان‌دهنده سطح متفاوتی از پتانسیل وقوع زمین لغزش در منطقه مورد مطالعه، می‌باشد.



شکل ۵- پهنه‌بندی حساسیت زمین لغزش حوضه مورد مطالعه با استفاده از الگوریتم شبکه عصبی مصنوعی
Fig. 5. Landslide susceptibility zoning in the study area using an artificial neural network

نتایج ارزیابی مدل شبکه عصبی مصنوعی در پنج کلاس حساسیت زمین لغزش در جدول ۲ ارائه شده است. بر اساس این نتایج، مدل در معیار Sensitivity بهترین عملکرد را در کلاس ۴ (۰/۸۷۱۷) و کمترین عملکرد را در کلاس ۱ (۰/۸۰۶) نشان داد. در معیار Specificity، بالاترین مقدار در کلاس ۱ (۰/۹۹۲۱) و کمترین مقدار در کلاس ۵ (۰/۹۰۱۸) مشاهده شد. مدل در این شاخص عملکرد بسیار بالایی در محاسبه داشته است.

ارزیابی معیار PPV نشان داد مدل در کلاس ۳ (۰/۸۷۹۴) بهترین و در کلاس ۵ (۰/۵۲۷۱) ضعیف‌ترین عملکرد را داشته است. برای معیار NPV، بیشترین مقدار در کلاس ۱ (۰/۹۹۳۶) و کمترین مقدار در کلاس ۳ (۰/۸۸۹۵) ثبت شد. معیار Prevalence در کلاس ۲ (۹۹۰۱/۰) بالاترین و در کلاس ۳ (۸۴۰۰/۰) پایین‌ترین مقدار را نشان داد.

در معیار Detection Rate، مدل در کلاس ۴ (۰/۸۷۹) بهترین و در کلاس ۱ (۰/۶۰۰) ضعیف‌ترین عملکرد را داشت. برای معیار Detection Prevalence، بیشترین مقدار در کلاس ۱ (۰/۹۹۱۶) و کمترین مقدار در کلاس ۴ (۰/۷۰۵۴) مشاهده شد. دقت کلی مدل (Accuracy) در کلاس ۴ (۰/۹۱۰۱) به حداکثر و در کلاس ۱ (۰/۷۹۶۰) به حداقل رسید. به‌طور کلی الگوریتم شبکه عصبی با عملکرد و دقت بالا کلاس‌های حساسیت زمین لغزش را محاسبه نموده است (جدول ۲).

جدول ۲- مشخصات کلاس بندی زمین لغزش با استفاده از الگوریتم شبکه عصبی مصنوعی

Table 2- Landslide classification specifications using the artificial neural network algorithm

Class 5	Class 4	Class 3	Class 2	Class 1	
0.8285	0.8717	0.8611	0.8400	0.8060	حساسیت Sensitivity
0.9018	0.9918	0.9279	0.9048	0.9921	ویژگی Specificity
0.5271	0.8316	0.8794	0.8607	0.5454	ارزش پیش بینی مثبت Positive Predictive Value (PPV)
0.9901	0.9465	0.8898	0.9618	0.9936	ارزش پیش بینی منفی Negative Predictive Value (NPV)
0.8992	0.9048	0.8400	0.9901	0.9302	شیوع Prevalence
0.8285	0.8790	0.7845	0.7527	0.6000	نرخ تشخیص Detection Rate
0.8011	0.7054	0.8992	0.9921	0.9916	شیوع تشخیص Detection Prevalence
0.9037	0.9101	0.8995	0.8829	0.7960	دقت Accuracy

همان طور که در جدول ۳ نشان داده شده است، مناطق مستعد زمین لغزش بسیار کم با مساحت ۴۱/۲۶ کیلومتر با ۱۰/۱۲ درصد از کل، مناطق زمین لغزش با خطر کم با مساحت ۴۴/۳۲ کیلومتر با ۱۲/۵۸ درصد، مناطق مستعد لغزش با خطر متوسط با مساحت ۷۳/۲۵ کیلومتر با ۲۷/۷۱ درصد، مناطق مستعد زمین لغزش با خطر زیاد با مساحت ۷۵/۳۷ کیلومتر با ۳۰/۳۱ درصد و مناطق مستعد لغزش خطر خیلی زیاد با مساحت ۶۱/۱۰ کیلومتر با ۱۹/۱۰ درصد به خود اختصاص داده اند. در نتایج نقشه برداری پیش بینی خطر زمین لغزش، حوضه مورد مطالعه، در سطح زیاد و متوسط قرار گرفته است.

جدول ۳- توزیع مساحت و درصد درجات خطر زمین لغزش

Table 3- Area distribution and percentage of landslide hazard levels

درصد Percentage	مساحت (کیلومتر) Area (km ²)	کلاس خطر Hazard Class
10.12	41.26	خیلی کم Very Low
12.58	44.32	کم Low
27.71	73.25	متوسط Medium
30.31	75.37	زیاد High
19.10	61.10	خیلی زیاد Very High

در ادامه به محاسبه معیارهای اعتبارسنجی ۳۰ درصد (آزمایشی) به ۷۰ درصد (آموزشی) در نرم افزار Rstudio پرداخته گردید. همانطور که در جدول ۴ مشاهده می گردد، اعتبارسنجی الگوریتم شبکه عصبی مصنوعی با معیار Accuracy برابر با (۰/۸۵۴۳) نشان می دهد مدل در مجموع عملکرد خوبی دارد. ضریب کاپا برابر با (۰/۷۶۴۷)، با در نظر گرفتن احتمال توافق تصادفی مقدار بالا (نزدیک به ۱) نشان می دهد که توافق بسیار خوبی، بین پیش بینی ها و مقادیر واقعی وجود دارد. RMSE با توجه به مقدار کم آن (۰/۰۰۶۸)، مدل پیش بینی های دقیقی انجام داده است. معیار Rsquared، (۰/۹۹۱۶) با توجه مقدار بالا (نزدیک به ۱) نشان می دهد که مدل به خوبی حساسیت زمین لغزش را توضیح داده است و در نهایت نتایج MAE (۰/۰۰۵۲) به دست آمده است. به طور کلی، نتایج نشان می دهند که مدل شبکه عصبی مصنوعی با دقت و عملکرد خوبی در جهت حساسیت زمین لغزش محاسبه شده است.

جدول ۴- نتایج اعتبار سنجی الگوریتم شبکه عصبی مصنوعی

Table 4- Artificial neural network algorithm validation results

0.8543	Accuracy (دقت)
0.7647	Kappa (ضریب کاپا)
0.0068	RMSE (ریشه میانگین مربعات)
0.9916	Rsquared (ضریب تعیین)
0.0052	MAE (میانگین مطلق خطا)

نتیجه‌گیری

این مطالعه با هدف ارزیابی حساسیت زمین‌لغزش در حوضه آبریز سد شهید عباسپور انجام گردید و نتایج حاصل از آن حاوی نکات مهمی برای مدیریت ریسک و برنامه‌ریزی محیطی است. پژوهش حاضر نشان داد که پدیده زمین‌لغزش به‌عنوان یکی از چالش‌های مهم در مناطق مستعد بلایای طبیعی، نیازمند توجه، ویژه است. بر اساس بررسی‌های میدانی در روستاهای زیرکوه شالو، آب گنجشکی، ابوک و دوروه، عوامل مؤثر بر حساسیت زمین‌لغزش به‌ترتیب اهمیت شامل فاصله از رودخانه، شیب و سازندهای زمین‌شناسی بوده‌اند، در حالی که ارتفاع و انحنای دامنه کمترین تأثیر را داشته‌اند.

یافته‌های تحقیق نشان می‌دهد که حدود ۳۱/۳ درصد از منطقه مورد مطالعه (معادل ۷۵/۳۷ کیلومترمربع) در کلاس حساسیت زیاد و خیلی زیاد قرار دارد که این مساحت قابل توجه، لزوم توجه جدی به این پدیده را نشان می‌دهد. بررسی عوامل تأثیرگذار نشان داد که فاصله از رودخانه با تأثیر ۲۷/۸ درصد، مهم‌ترین عامل در وقوع زمین‌لغزش است. مکانیسم تأثیر رودخانه‌ها شامل سه فرآیند اصلی فرسایش پای‌دامنه‌ها و کاهش پایداری شیب، افزایش رطوبت خاک و کاهش مقاومت برشی و نوسانات سطح آب زیرزمینی می‌باشد. همچنین پارامتر شیب با سهم ۲۳/۵ درصدی به‌عنوان دومین عامل مهم شناسایی شد. مناطق با شیب بیش از ۳۵ درجه بیشترین حساسیت را نشان دادند. سازندهای زمین‌شناسی با تأثیر ۲۱/۹ درصدی در رتبه سوم قرار گرفتند، به‌طوری که سازندهای مارنی گچساران و آبرفت‌های کواترنری بیشترین آسیب‌پذیری را داشتند.

مدل شبکه عصبی توسعه‌یافته با دقت کلی ۸۵/۴۳ درصد و ضریب تعیین ۹۹/۱۶ درصد، عملکرد بسیار مطلوبی از خود نشان داد. تحلیل معیارهای مختلف نشان می‌دهد که مدل در شناسایی مناطق پرخطر موفق عمل کرده و نشان‌دهنده دقت بالا در پیش‌بینی مناطق پرخطر است.

همچنین، اعتبارسنجی الگوریتم شبکه عصبی مصنوعی با معیار Accuracy برابر با (۰/۸۵۴۳) و معیار Rsquared (۰/۹۹۱۶) نشان می‌دهد مدل در مجموع عملکرد خوبی دارد. نتایج کلاس‌های حساسیت زمین‌لغزش در عملکرد معیار Sensitivity به ترتیب از کمترین به بیشترین، کلاس ۱ (۰/۸۰۶۰)، کلاس ۵ (۰/۸۲۸۵)، کلاس ۲ (۰/۸۴۰۰)، کلاس ۳ (۰/۸۶۱۱) و کلاس ۴ (۰/۸۷۱۷)، برآورد شده‌اند. به‌طور کلی، الگوریتم شبکه عصبی با عملکرد و دقت بالا، کلاس‌های حساسیت زمین‌لغزش را محاسبه نموده است. طبقه‌بندی حساسیت زمین‌لغزش، به‌ویژه برای مناطق با حساسیت بالا و متوسط، از دقت و قابلیت اطمینان مناسبی برخوردار است. این موضوع اهمیت زیادی برای مدیریت ریسک، هشدار زودهنگام و برنامه‌ریزی کاربری اراضی در مناطق مستعد زمین‌لغزش دارد. مناطق با حساسیت خیلی پایین ممکن است نیاز به بررسی‌های تکمیلی داشته باشند تا از عدم وجود خطای منفی اطمینان حاصل شود. بنابراین پیشنهاد می‌گردد:

- پایداری شیب‌ها با روش‌های مهندسی مانند میخکوبی، شمع کوبی یا ژئوگرید.
- استفاده از نقشه‌های حساسیت زمین‌لغزش با دقت بالا (مانند مدل‌های شبکه عصبی مصنوعی با دقت بیش از ۹۰ درصد) در برنامه‌ریزی‌های منطقه‌ای.
- ایجاد سیستم‌های هشدار زودهنگام برای مناطق پرخطر، به‌خصوص در زمان بارندگی‌های شدید.

- کنترل و هدایت مناسب آب‌های سطحی در مناطق مستعد لغزش.
 - جلوگیری از نشت آب لوله‌های انتقال و مخازن ذخیره آب در دامنه‌ها.
 - مدیریت آبیاری در زمین‌های کشاورزی واقع در شیب‌ها.
 - استقرار سیستم‌های پایش مداوم تغییرات سطح زمین در مناطق با حساسیت بالا.
 - بررسی‌های دوره‌ای مناطق پرخطر، به ویژه پس از بارندگی‌های شدید یا زلزله.
 - به‌روزرسانی نقشه‌های حساسیت زمین‌لغزش با داده‌های جدید.
- با توجه به گستردگی مناطق پرخطر در حوضه مورد مطالعه، اجرای برنامه‌های مدیریت ریسک یک ضرورت انکارناپذیر است. ترکیب راهکارهای سازه‌ای و غیرسازه‌ای با سیستم‌های پایش پیشرفته می‌تواند به کاهش قابل توجه خسارات ناشی از این پدیده منجر شود. نتایج این مطالعه می‌تواند مبنای علمی بسیار مناسبی برای تصمیم‌گیری‌های مدیریتی در منطقه باشد.

سپاسگزاری

تیم پژوهشی مراتب قدردانی صمیمانه خود را از دانشگاه اصفهان به دلیل ارائه حمایت مالی ضروری و امکانات پژوهشی که این پژوهش را ممکن ساخت، ابراز می‌دارد. همچنین، از مشارکت سازمان‌های مختلف در ارائه داده‌ها و کمک‌های فنی با سپاسگزاری یاد می‌شود.

References

- Ali Bakhshi, T., Azizi, Z., Vafaeinejad, A., & Aghamohammadi Zanjirabadi, H. (2020). Survey of area changes in water basins of Shahid Abbaspour Dam caused by 2019 floods using Google Earth Engine. *Ecohydrology*, 7(2), 345–357. [In Persian] <https://doi.org/10.22059/ije.2020.295785.1272>
- Bao, Y., Zhai, S., Chen, J., Xu, P., Sun, X., Zhan, J., ... & Zhou, X. (2020). The evolution of the Samaoding paleo-landslide river blocking event at the upstream reaches of the Jinsha River, Tibetan Plateau. *Geomorphology*, 351, 106970. <https://doi.org/10.1016/j.geomorph.2020.106970>
- Benmakhlof, M., El Kharim, Y., Galindo-Zaldívar, J., & Sahrane, R. (2023). Landslide susceptibility assessment in Western External Rif Chain using machine learning methods. *Civil Engineering Journal*, 9(12), 3045–3060. <https://doi.org/10.28991/CEJ-2023-09-12-018>
- Esfandiary Darabad, F., Rahimi, M., Navidfar, A., & Arsalan, M. (2020). Assessment of landslide sensitivity by neural network method and vector machine algorithm (Case study: Heyran Road, Ardabil Province). *Quantitative Geomorphological Research*, 9(3), 18–33. [In Persian] <https://doi.org/10.22034/gmpj.2020.122210>
- Geological and Mineral Exploration Organization of Iran. (2018). Identification of landslide susceptibility in the city of Masjed-e-Suleiman, General Directorate of the South Western Region (Ahvaz). [In Persian]
- Ghaedi, S., Amouzegar, S., & Shojaiean, A. (2022). Landslide microzonation using fuzzy grey correlation analysis (case study: Mollaghafar drainage basin, northeast of Khuzestan Province). *Advanced Applied Geology*, 12(2), 337–350. [In Persian] <https://doi.org/10.22055/AAG.2021.36387.2195>
- He, Q., Shahabi, H., Shirzadi, A., Li, S., Chen, W., Wang, N., ... & Ahmad, B. B. (2019). Landslide spatial modelling using novel bivariate statistical based Naïve Bayes, RBF Classifier, and RBF Network machine learning algorithms. *Science of the Total Environment*, 663, 1–15. <https://doi.org/10.1016/j.scitotenv.2019.01.329>
- Hejazi, A., Rezaeimoghaddam, M., & Naseri, A. (2020). Landslide hazard zoning using artificial neural network models and TOPSIS downstream of Sanandaj Dam. *Hydrogeomorphology*, 7(24), 65–82. [In Persian] <https://doi.org/10.22034/hyd.2020.11060>
- Hungr, O., Leroueil, S., & Picarelli, L. (2024). The Varnes classification of landslide types, an update. *Landslides*, 11, 167–194. <https://doi.org/10.1007/s10346-013-0436-y>

- Ma, S., Chen, J., Wu, S., & Li, Y. (2023). Landslide susceptibility prediction using machine learning methods: A case study of landslides in the Yinghu Lake Basin in Shaanxi. *Sustainability*, *15*, 15836. <https://doi.org/10.3390/su152215836>
- Majd-Bavi, A., & Mumipour, M. (2022). Landslide susceptibility zonation in Shahid Abbaspour Dam district. *Journal of Geography and Environmental Hazards*, *10*(1), 65-80. [In Persian] <https://doi.org/10.22067/geoeh.2021.67029.0>
- Masruroh, H., Leksono, A. S., & Kurniawan, S. (2023). Developing landslide susceptibility map using Artificial Neural Network (ANN) method for mitigation of land degradation. *Journal of Degraded & Mining Lands Management*, *10*(3), 4479-4494. <https://doi.org/10.15243/jdmlm.2023.103.4479>
- Mohammadi, A., Shahabi, H., & Bin Ahmad, B. (2018). Integration of InSAR technique, Google Earth images and extensive field survey for landslide inventory in a part of Cameron Highlands, Pahang, Malaysia. *Applied Ecology & Environmental Research*, *16*(6), 8075-8091. https://dx.doi.org/10.15666/aeer/1606_80758091
- Mohammadi, M., Afifi, M. A., & Ghanbari, A. R. (2023). Landslide hazard zoning using a fuzzy inference system in the Izeh River basin. *Geographical Sciences*, *19*(42), 156-176. [In Persian] <https://sanad.iau.ir/fa/Journal/geographic/Article/919283>
- Mostofi, N. (2013). *MATLAB User Guide*. Tehran Publications. [In Persian]
- Mousavi Nadushan, S. S. (2012). *Introduction to the R computing language*. Tehran, Iran: Shahid Abbaspour University of Water and Electricity Industry. [In Persian]
- Pollock, W., Grant, A., Wartman, J., & Abou-Jaoude, G. (2019). Multimodal method for landslide risk analysis. *MethodsX*, *6*, 827-836.
- Rahaman, A., Dondapati, A., Gupta, S., & Raj, R. (2024). Leveraging artificial neural networks for robust landslide susceptibility mapping: A geospatial modeling approach in the ecologically sensitive Nilgiri District, Tamil Nadu. *Geohazard Mechanics*, *2*(4), 258-269. <https://doi.org/10.1016/j.ghm.2024.07.001>
- Rajabi, M., Rezaeimoghadam, M., & Takzare, A. (2020). Landslide hazard potential zoning using the neural network method (Case study: Alamut watershed in Qazvin Province). *Quantitative Geomorphological Research*, *9*(3), 185-171. [In Persian] <https://doi.org/10.22034/gmpj.2020.122223>
- Sadati, S. H., Mousavi, S. R., Vahabzadeh Kebria, G., & Roshun, S. H. (2025). Evaluation of random forest and support vector machine models in landslide risk mapping (Case study: Tajan Basin, Mazandaran Province). *Journal of Natural Environmental Hazards*, 1-1. [In Persian] <https://doi.org/10.22111/jneh.2025.50031.2071>
- Sadeghi Balochi, M., & Alian, S., (2025), Landslide Hazard Assessment and Visualization Using Artificial Neural Network Method (Case Study of Lahijan County). Paper presented at the Proceedings of the 16th International Conference of the Iranian Society for Operations Research, Ramsar. [In Persian] <https://civilica.com/doc/1920698>
- Selamat, S. N., Majid, N. A., Taha, M. R., & Osman, A. (2022). Landslide Susceptibility Model Using Artificial Neural Network (ANN) Approach in Langat River Basin, Selangor, Malaysia. *Land*, *11*, 833. <https://doi.org/10.3390/land11060833>
- Sun, D., Ding, Y., Zhang, J., Wen, H., Wang, Y., Xu, J., ... & Liu, R. (2022). Essential insights into decision mechanism of landslide susceptibility mapping based on different machine learning models. *Geocarto International*, 1-29. <https://doi.org/10.1080/10106049.2022.2146763>
- Sun, X., Chen, J., Han, X., Bao, Y., Zhan, J., & Peng, W. (2020). Application of a GIS-based slope unit method for landslide susceptibility mapping along the rapidly uplifting section of the upper Jinsha River, South-Western China. *Engineering Geology and the Environment*, *79*, 533-549. <https://doi.org/10.1007/s10064-019-01572-5>

- Talaei, R., & Shadfar, S. (2023). Landslide susceptibility modeling using artificial neural network and logistic regression methods at the Saqezchay Basin, south of Ardabil Province. *Watershed Engineering and Management*, 15(3), 481-503. [In Persian] <https://doi.org/10.22092/ijwmse.2022.360475.1996>
- Tayebi far, A. (2024). Preparing Landslide Hazard Sensitivity Maps Using Machine Learning Methods (Case Study: Kermanshah). (Master's Thesis). University of Isfahan .[In Persian]
- Wahba, M., Essam, R., El-Rawy, M., Al-Arifi, N., Abdalla, F., & Elsadek, W. M. (2024). Forecasting of flash flood susceptibility mapping using random forest regression model and geographic information systems. *Heliyon*, 10(13), e33982. <https://doi.org/10.1016/j.heliyon.2024.e33982>
- Zakerinejad, R., & Amoshahi, N. (2022). Assessment of Landslide Hazard Using Remote sensing data and the Maximum Entropy Model (Case Study: Kome watershed, in south of Isfahan Province). *Quantitative Geomorphological Research*, 11(2), 128-149. [In Persian] <https://doi.org/10.22034/gmpj.2022.340900.1349>