

# Landslide susceptibility modeling using artificial neural network and logistic regression methods at the Saqezchay Basin, south of Ardabil Province

Reza Talaei<sup>1\*</sup> and Samad Shadfar<sup>2</sup>

<sup>1</sup>Assistant Professor, Soil Conservation and Watershed Management Research Department, Ardabil Agricultural and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization (AREEO), Ardabil, Iran

<sup>2</sup>Associate Professor, Soil Conservation and Watershed Management Research Institute (SCWMRI), Agricultural Research, Education and Extension Organization (AREEO), Tehran, Iran

Received: 02 August 2022 Accepted: 21 November 2022

## Extended abstract

### Introduction

Landslides are one of the natural hazards in mountainous areas that threaten the safety of residents and the environment. In the past few decades, landslides have caused damage to natural and human resources in the Saqezchi Basin in the south of Ardabil Province. Landslides have occurred in more than 9.2% (2600 ha) of the area. In this basin, like other landslide areas, for land-use planning and management, it is necessary to analyze the whole area in order to estimate the probability of landslides occurrence in the future. It is possible to solve this problem by analyzing the geomorphology, topography, geology, land use, hydrology and climate factors of the basin in the form of information layers in the geographic information systems on a regional scale. Landslide susceptibility assessment has not been done with modern methods and with high accuracy in the Saqzachai Basin until now. The results of this research can be used in predicting the possible occurrence of landslides and reducing damage in the Saqzachai Basin.

### Materials and methods

The research basin with an area of 27,918 ha is located in the south of Ardabil Province and in the southwest of Khalkhal City. In this basin, the inventory map was generated based on 113 landslides, the training dataset and validation dataset were, respectively, prepared using 70% landslides and the remaining 30% landslides. Ten landslide causative factors based on slope angle, slope aspect, distance to faults, distance to stream network, distance to the roads, distance to settlement area, lithology, land-use, peak ground acceleration (PGA) and average annual precipitation were applied for the models analysis. Two nonlinear methods of neural network called multi-layer perceptron with feed forward structure and logistic regression were used to predicting the susceptibility of landslide occurrence. The probability of landslide occurrence in each pixel was calculated based on both models. The prediction accuracy of the two models were evaluated using the Receiver Operating Characteristic (ROC) curve.

### Results and discussion

In the neural network model, landslides triggering factors, including the average annual precipitation (0.136) and the peak ground acceleration (0.134), have been the greatest effect in predicting the probability of landslides. The factors of slope angle (0.067), slope aspect (0.069), distance to faults (0.110), distance to stream network (0.101), distance to the roads (0.109), distance to settlement area (0.096), lithology (0.109) and land-use (0.068) are respectively important in landslides susceptibility modeling to using artificial neural

\* Corresponding author: talaei1969@yahoo.com

networks. Therefore, all ten factors were used in modeling by artificial neural networks. The results indicated that the probability of landslide occurrence varies from 0.00 to 0.961. In the classification of the watershed according to the degree of landslide susceptibility by the natural breaks method based on the estimated probability by the neural network method, 85.7% of the area is placed in the zones with low and very low susceptibility. In 6.6% of the area, there is a probability of moderate susceptibility, and in 7.7%, there is a high and very high landslide susceptibility. Landslide susceptibility analysis is started without independent variable and ended by adding variables in the tenth step using logistic regression method. The results show that only three levels of the factor of slope aspect are ineffective in the logistic regression model. Probability values were calculated between 0 and 1 for all pixels in the area based on the values of independent variables by estimating constant and coefficients related to logistic regression model. The landslide-prone areas of low and very low susceptibility, medium susceptibility and high to extremely high-susceptibility grades are 79.9%, 10.1%, and 10%, of area, respectively, by the natural breaks method in the logistic regression model. The accuracy and validity of the logistic regression and artificial neural network models based on the ROC curve and the area under it (AUC) are equal to 0.848 and 0.929, respectively. The findings of the models show good results with the accuracy of two models being higher than 84%. The results obtained from two methods in most studies in the world and in Iran indicate their ability to accurately estimate susceptibility to landslides occurrence, but the artificial neural network method is more accurate despite its specific complexities.

### Conclusion

Landslides are an important limitation for development in the landslide areas in the south of Ardabil Province. The environmental conditions in the Saqzachi Basin are susceptible to the occurrence of new landslides or the reactivation of old landslides. The probability of landslides occurrence was simulated using effective factors and using logistic regression and artificial neural network models in the region. The results obtained from the artificial neural network model are the most accurate and better than the logistic regression model. The landslides triggering factors, including the average annual precipitation and the peak ground acceleration have the greatest impact to predicting the probability of landslide occurrence using the artificial neural network model. The findings of the models show good results with the accuracy of two models being higher than 84%. The artificial neural network method is superior in explaining the relationship between landslide occurrence and influencing factors. The landslide susceptibility map was prepared using this method by dividing into five class, namely: very low (71.4%), low (14.3%), moderate (6.6%), high (4.3%) and very high (3.4%) susceptibility zones. Therefore, it is recommended to use the artificial neural network models in landslide susceptibility assessment in the basin and similar regions to help decision makers, planners, land use managers and government agencies in hazard and damage reduction.

**Keywords:** Accuracy, Assessment, Damage, Effective factors, Natural hazards, Prediction and probability

Cite this article: 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.

© 2023, 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>).



## مدلسازی حساسیت به زمین لغزش با استفاده از شبکه‌های عصبی مصنوعی و رگرسیون لجستیک در حوضه سقزچای جنوب استان اردبیل

رضا طلائی<sup>۱</sup> و صمد شادفر<sup>۲</sup>

<sup>۱</sup> استادیار، بخش تحقیقات حفاظت خاک و آبخیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان اردبیل (مغان)، سازمان تحقیقات، آموزش و ترویج کشاورزی، اردبیل، ایران

<sup>۲</sup> دانشیار، پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

تاریخ دریافت: ۱۴۰۱/۰۵/۱۱ تاریخ پذیرش: ۱۴۰۱/۰۸/۳۰

### چکیده مبسوط

#### مقدمه

زمین لغزش‌ها، یکی از مخاطرات طبیعی در مناطق کوهستانی هستند که ایمنی ساکنان و محیط زیست را تهدید می‌کنند. در چند دهه گذشته، زمین لغزش‌ها در حوضه سقزچای در جنوب استان اردبیل، باعث وارد شدن خسارت‌هایی به منابع طبیعی و انسانی شده‌اند. زمین لغزش‌ها، در بیش از ۹/۲ درصد (۲۶۰۰ هکتار) از مساحت این حوضه وجود دارند. در این حوضه نیز مانند سایر مناطق زمین لغزشی، برای برنامه‌ریزی و مدیریت اراضی نیاز به تحلیل کل منطقه است، تا بر اساس آن احتمال وقوع زمین لغزش در آینده برآورد شود. حل این موضوع با تحلیل توام ویژگی‌های ژئومورفولوژی، توپوگرافی، زمین-شناسی، کاربری اراضی، هیدرولوژی و آب و هوایی حوضه در قالب لایه‌های اطلاعاتی در محیط سامانه‌های اطلاعات جغرافیایی در یک مقیاس منطقه‌ای، امکان‌پذیر است. ارزیابی حساسیت به زمین لغزش در حوضه سقزچای تا به حال با روش‌های نوین و با دقت بالا انجام نگرفته است. دقت و اعتبار هر مدل، با استفاده از روش منحنی ROC و بر مبنای سطح زیر آن (AUC) تعیین شد. نتایج به دست آمده از این پژوهش، می‌تواند در پیش‌بینی وقوع احتمالی زمین لغزش و کاهش خسارت در حوضه سقزچای مورد استفاده قرار گیرد.

#### مواد و روش‌ها

حوضه مورد پژوهش، با مساحت ۲۷۹۱۸ هکتار در جنوب استان اردبیل و در جنوب غرب شهرستان خلخال واقع شده است. در این حوضه، نقشه پراکنش ۱۱۳ زمین لغزش تهیه شد که در آن به ترتیب ۷۰ و ۳۰ درصد از زمین لغزش‌ها به داده‌های آموزشی و ارزیابی اختصاص داده شدند. ده عامل موثر، در وقوع زمین لغزش‌ها شامل درصد شیب، جهات شیب، فاصله از گسل‌ها، فاصله از رودخانه‌ها، فاصله از راه‌ها، فاصله از مناطق مسکونی، واحدهای سنگ‌شناسی، بیشینه شتاب افقی زمین، کاربری اراضی و مجموع بارندگی سالانه، در تحلیل مدل‌ها مورد استفاده قرار گرفتند. به منظور پیش‌بینی حساسیت به وقوع زمین لغزش، از دو روش غیرخطی شبکه عصبی به نام پرسپترون چند لایه با ساختار رو به جلو و رگرسیون لجستیک، استفاده شد. بر اساس هر دو مدل، احتمال وقوع زمین لغزش در هر پیکسل محاسبه شد. دقت پیش‌بینی دو مدل با استفاده از منحنی ROC، مورد ارزیابی قرار گرفت.

## نتایج و بحث

در مدل شبکه‌های عصبی، عوامل تشدید کننده شامل میانگین بارندگی سالانه (۰/۱۳۶) و بیشینه شتاب افقی زمین (۰/۱۳۴)، بیشترین تاثیر را در پیش‌بینی احتمال وقوع زمین‌لغزش‌ها داشته‌اند. عوامل فاصله از گسل‌ها (۰/۱۱۰)، واحدهای سنگ‌شناسی (۰/۱۰۹)، فاصله از راه‌ها (۰/۱۰۹)، فاصله از رودخانه‌ها (۰/۱۰۱)، فاصله از مناطق مسکونی (۰/۰۹۶)، جهات جغرافیایی دامنه‌ها (۰/۰۶۹)، کاربری اراضی (۰/۰۶۸) و درصد شیب دامنه‌ها (۰/۰۶۷) به ترتیب در مدل‌سازی حساسیت به زمین‌لغزش به روش شبکه‌های عصبی مصنوعی اهمیت دارند. بنابراین، تمامی ده عامل در مدل‌سازی به روش شبکه‌های عصبی مصنوعی، به کار گرفته شدند. نتایج به دست آمده نشان داد که احتمال وقوع زمین‌لغزش در فاصله ۰/۱۰ تا ۰/۹۶۱، تغییر می‌نماید. در طبقه‌بندی حوضه به درجات حساسیت به زمین‌لغزش، به روش شکست طبیعی بر مبنای احتمال برآوردی روش شبکه‌های عصبی، ۸۵/۷ درصد از منطقه در پهنه‌های با حساسیت کم و بسیار کم، قرار می‌گیرد. ۶/۶ درصد از منطقه، احتمال حساسیت به زمین‌لغزش متوسط و در ۷/۷ درصد از حوضه حساسیت بالا و بسیار بالا برای وقوع زمین‌لغزش وجود دارد. تحلیل حساسیت به زمین‌لغزش به روش رگرسیون لجستیک، با روش بدون متغیر مستقل شروع شد و با اضافه کردن متغیرها در قدم دهم، خاتمه یافت. نتایج نشان می‌دهد که تنها سه سطح از عامل جهات جغرافیایی، در مدل رگرسیون لجستیک بی‌اثر هستند. با تخمین ثابت و ضرایب مربوط به متغیرهای مستقل در تحلیل رگرسیون لجستیک، مقادیر احتمال بین صفر تا یک، برای تمام پیکسل‌های منطقه محاسبه شد. با درجه‌بندی حساسیت به زمین‌لغزش به روش شکست طبیعی در مدل رگرسیون لجستیک، به ترتیب ۷۹/۹، ۱۰/۱ و ۱۰ درصد از مساحت منطقه در گروه با درجات حساسیت پایین و بسیار پایین، متوسط و بالا و بسیار بالا قرار می‌گیرد. دقت و اعتبار مدل‌های رگرسیون لجستیک و شبکه عصبی مصنوعی، بر اساس منحنی ROC و سطح زیر آن (AUC) به ترتیب برابر ۰/۸۴۸ و ۰/۹۲۹ است. نتایج هر دو مدل، خوب بوده است و دقت بالاتر از ۸۴ درصد داشته‌اند. نتایج به دست آمده از دو روش فوق، در اکثر مطالعات در دنیا و ایران حکایت از توانمندی آن‌ها در برآورد دقیق حساسیت احتمالی به زمین‌لغزش‌ها دارد، اما روش شبکه‌های عصبی مصنوعی، با وجود پیچیدگی‌های خاص دارای دقت بیشتری است.

## نتیجه‌گیری

زمین‌لغزش، یک محدودیت مهم برای توسعه در مناطق لغزش‌خیز جنوب استان اردبیل است. شرایط محیطی، در حوضه سقزچی برای وقوع زمین‌لغزش‌های جدید و یا فعالیت زمین‌لغزش‌های قدیمی مستعد است. احتمال وقوع زمین‌لغزش در منطقه با استفاده از عوامل موثر و به روش رگرسیون لجستیک و شبکه عصبی مصنوعی، شبیه‌سازی شد. نتایج حاصل از مدل شبکه عصبی مصنوعی، دقیق‌تر بوده و بهتر از مدل رگرسیون لجستیک است. در مدل شبکه‌های عصبی مصنوعی، عوامل تشدید کننده زمین‌لغزش‌ها شامل میانگین بارندگی سالانه و بیشینه شتاب افقی زمین، بیشترین تاثیر را بر چگونگی پیش‌بینی احتمال وقوع زمین‌لغزش‌ها دارند. روش شبکه عصبی مصنوعی، در تبیین رابطه وقوع زمین‌لغزش با عوامل موثر، برتری نشان داد. نقشه حساسیت خروجی از این مدل، به پنج طبقه حساسیت بسیار کم (۷۱/۴ درصد)، کم (۱۴/۳ درصد)، متوسط (۶/۶ درصد)، زیاد (۴/۳ درصد) و بسیار زیاد (۳/۴)، تقسیم شد. استفاده از مدل‌های شبکه عصبی مصنوعی، در ارزیابی حساسیت به زمین‌لغزش در حوضه و مناطق مشابه، به منظور کمک به تصمیم‌گیران، برنامه‌ریزان، مدیران کاربری اراضی و سازمان‌های دولتی در کاهش خطرات و آسیب‌ها، توصیه می‌شود.

**واژه‌های کلیدی:** احتمال، ارزیابی، پیش‌بینی، خسارت، دقت، عوامل موثر و مخاطرات طبیعی

## مقدمه

زمین لغزش، معمولا در مناطق کوهستانی رخ می‌دهد و تهدیدی جدی برای ایمنی ساکنان و محیط زیست است (Huang et al., 2020). به دلیل شرایط خاص زمین‌شناسی، ژئومورفیک و آب و هوایی، وقوع زمین لغزش‌های جدید و یا فعالیت مکرر زمین لغزش‌های قدیمی در حوضه سقزچی در جنوب استان اردبیل باعث وارد شدن خسارت‌هایی به منابع طبیعی، اراضی کشاورزی، تأسیسات و پروژه‌های زیرساختی اصلی می‌شوند. زمین لغزش‌ها، باعث می‌شوند تا در بیش از ۹/۲ درصد از مساحت حوضه یعنی در بیش از ۲۶۰۰ هکتار از اراضی آن خسارت‌های مستقیم و غیرمستقیم زیادی بر منابع وارد شود.

ثبت ۱۱۳ مورد زمین لغزش در حوضه که حداقل ۶۰ درصد از آن‌ها در ۷۰ سال گذشته یک بار جابجایی داشته‌اند، نشان‌دهنده حجم بالایی از مواد سنگی و خاکی است که با سرعت‌های کم تا زیاد حرکت کرده و باعث تهدیدهای جانی و مالی می‌شوند (Talaei, 2018). در این حوضه نیز مانند سایر مناطق زمین لغزشی، برای برنامه‌ریزی و مدیریت اراضی نیاز به تحلیل کل دامنه های منطقه است تا بر اساس آن احتمال حساسیت به زمین لغزش در آینده تعیین شود (Saha et al., 2021). حل این موضوع، امروزه با تحلیل توام ویژگی‌های ژئومورفولوژی، توپوگرافی، زمین‌شناسی، کاربری اراضی، هیدرولوژی و آب و هوایی در قالب لایه‌های اطلاعاتی، در محیط سامانه‌های اطلاعات جغرافیایی<sup>۱</sup> در یک مقیاس منطقه‌ای امکان‌پذیر است (Pham et al., 2017; Tanyu et al., 2021; Hong et al., 2019; Pourghasemi and Rahmati, 2018).

در این پژوهش نیز سعی شد، احتمال وقوع زمین لغزش در آینده، با صرف زمان و هزینه بسیار کم و بر مبنای اتفاقات گذشته و لایه‌های اطلاعاتی موجود و با استفاده از روش‌های ریاضی و آماری، برآورد و پیش‌بینی شود. تحلیل حساسیت به زمین لغزش، با ورود عوامل

موثر در قالب متغیرهای مستقل به مدل انجام می‌گیرد. برای انتخاب عوامل موثر در وقوع زمین لغزش‌ها و تعریف متغیرها، ضوابط خاصی وجود ندارد (Zhang et al., 2022; Jianqiang et al., 2022). در این پژوهش، متغیرها بر اساس شرایط محیطی، نتایج مطالعات صحرایی و تحلیل خصوصیات زمین لغزش‌های منطقه انتخاب شدند.

روش‌های مختلفی در ارزیابی حساسیت به زمین لغزش در مقیاس ناحیه‌ای به کار برده می‌شود که می‌توان از روش‌های مبتنی بر نظر کارشناسان خبره (Thiery et al., 2014)، تحلیل‌های آماری (Barella; Demir, 2018)، مدل‌های فیزیکی (Rana and Babu, 2019) و مدل‌های نام برد. در سال‌های اخیر، داده‌کاوی و روش‌های یادگیری ماشین، مانند شبکه عصبی مصنوعی<sup>۲</sup> (Sepah Vand et al., 2017; Shirani et al., 2017; Shirani and Yilmaz, 2009; Liu, 2010; al., 2018; Naderi Samani, 2022; Bravo-López et al., 2022)، رگرسیون لجستیک (Xu et al., 2015; Meten et al., 2015)، ماشین بردار پشتیبان<sup>۳</sup> (Su and Arabameri, 2015) و ماشین بردار پشتیبان<sup>۳</sup> (Zhang et al., 2015; Zhang et al., 2022) به طور گسترده برای ارزیابی حساسیت به زمین لغزش استفاده شده‌اند و در عمل هم نتایج رضایت بخشی داشته‌اند.

بررسی منابع موجود نشان می‌دهد که تا به حال حساسیت به زمین لغزش در حوضه زمین لغزش سقزچای، با روش‌های نوین و با دقت بالا انجام نگرفته است. مطالعاتی در مناطق جنوبی استان، در خصوص توصیف ویژگی‌های کلی چند مورد از زمین لغزش‌ها (Nikandish and Mir; Ansari and Blurchi, 1996) عوامل اصلی موثر در وقوع زمین لغزش‌ها (Sanei, 1996) و پهنه‌بندی حساسیت به زمین لغزش، با استفاده از مدل کیفی صورت گرفته است (Hashemi Tabatabaei, 1998). همچنین، حساسیت به

<sup>2</sup> Artificial Neural Network (ANN)

<sup>3</sup> Support Vector Machine (SVM)

<sup>1</sup> Geographic Information Systems (GIS)

اراضی، فاصله از گسل‌های اصلی فعال و با طول بیش از پنج کیلومتر، فاصله از رودخانه‌ها، فاصله از مناطق مسکونی، مجموع بارندگی سالیانه و بیشینه شتاب افقی زمین (Peak Ground Acceleration, PGA)، برای ارزیابی حساسیت به زمین‌لغزش انتخاب شدند (شکل ۲). در ارزیابی حساسیت به زمین‌لغزش در منطقه، سه متغیر سنگ‌شناسی، جهات جغرافیایی دامنه‌ها و کاربری اراضی به صورت گسسته و بقیه عوامل، شامل درجه شیب، فاصله از گسل‌های اصلی فعال، فاصله از رودخانه‌ها، فاصله از مناطق مسکونی، مجموع بارندگی سالیانه و بیشینه شتاب افقی زمین، به صورت متغیرهای پیوسته وارد مدل شدند.

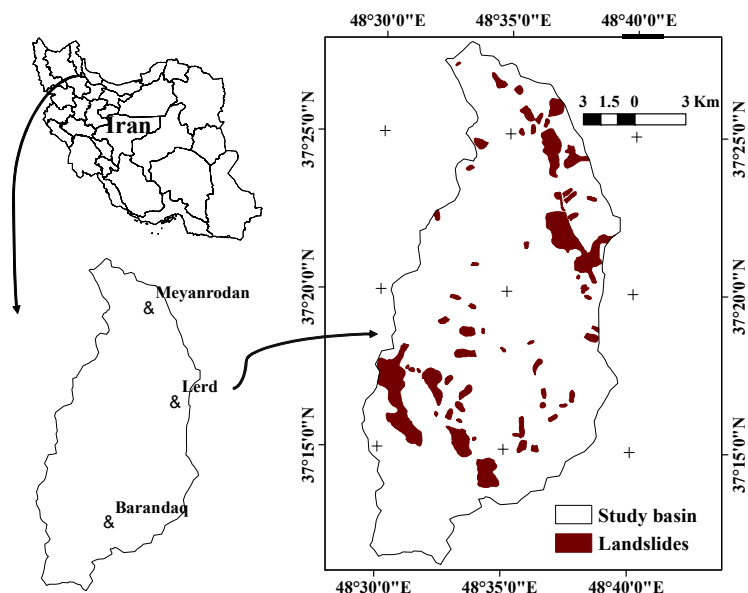
یکی از فلسفه‌های اصلی مقایسه‌ی توانایی مدل‌ها، در ارزیابی حساسیت به زمین‌لغزش نیز تفاوت آن‌ها در معیارهای انتخاب و وزن‌دهی به عوامل است. بر این اساس است که اهمیت و ضرایب متغیرها در دو مدل متفاوت هستند. به منظور ارزیابی و مقایسه توانایی دو مدل، ده متغیر مستقل با یک فرمت یکسان وارد محاسبات شدند.

زمین‌لغزش در سطح گسترده‌ای از مناطق جنوبی استان اردبیل با روش‌های مختلف آماری ارزیابی شده است (Talaei, 2018)، اما در مطالعات فوق، از روش‌هایی مانند شبکه‌های عصبی مصنوعی استفاده نشده است. در این پژوهش حاضر، با تشخیص مناطق زمین‌لغزش و تدقیق داده‌ها برای تهیه لایه‌های اطلاعاتی و استفاده از روش‌های شبکه‌های عصبی مصنوعی و رگرسیون لجستیک، اقدام به مدلسازی حساسیت به زمین‌لغزش و ارزیابی نتایج، شده است.

### مواد و روش‌ها

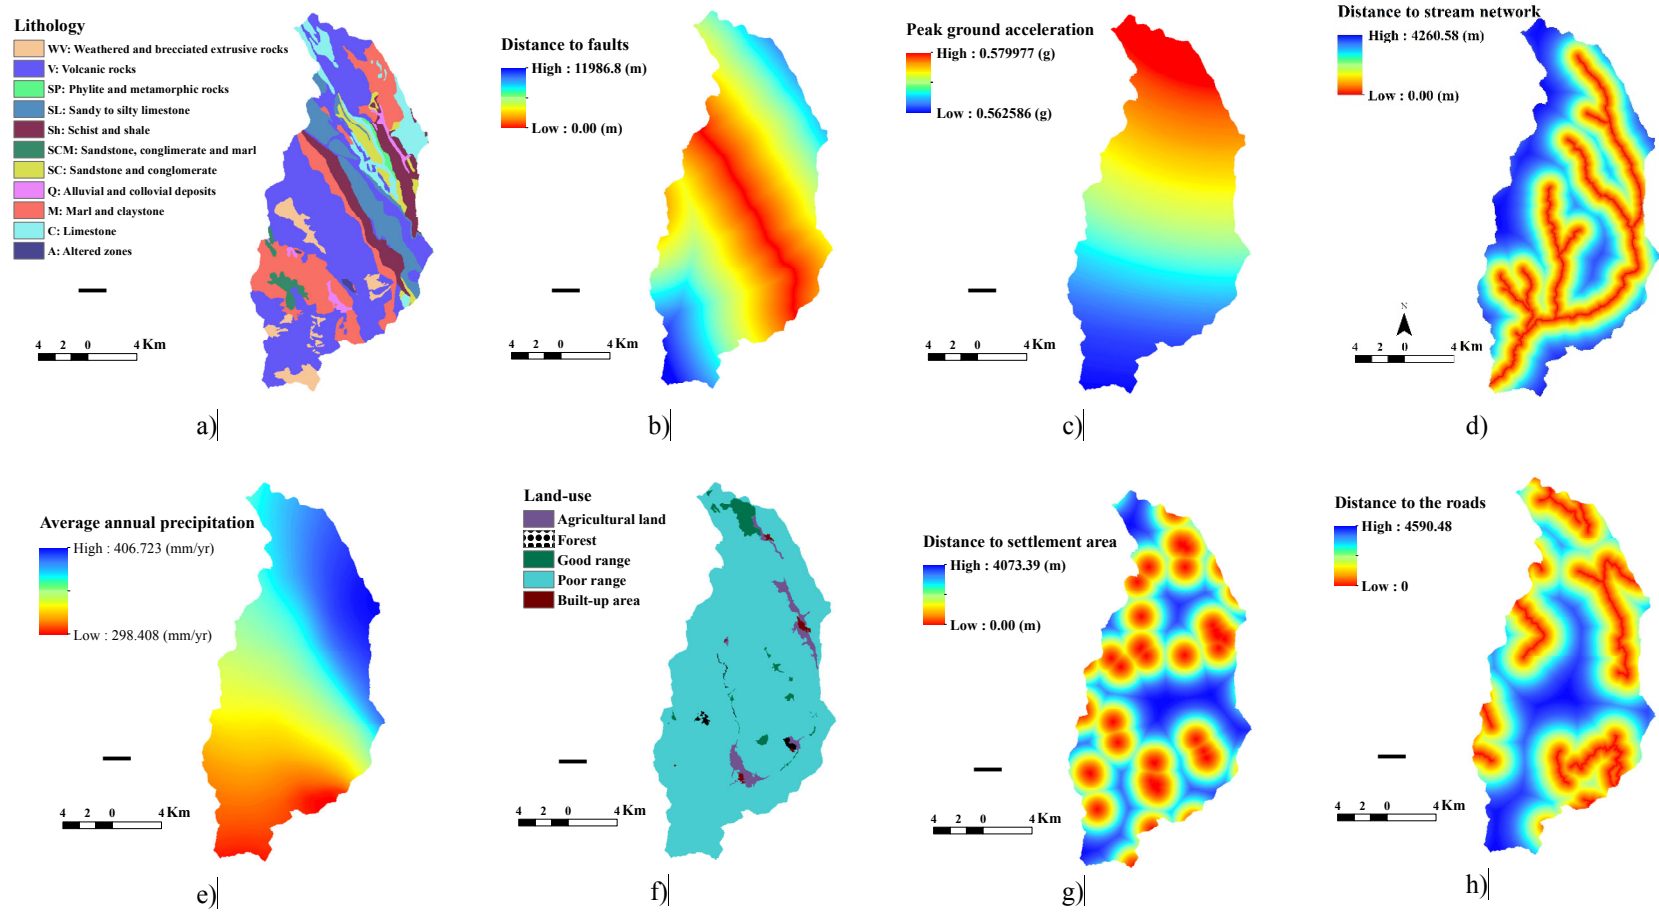
**منطقه مورد پژوهش:** حوضه سقزچای، با مساحت ۲۷۹۱۸ هکتار، در جنوبی‌ترین نقطه استان اردبیل و در جنوب غرب شهرستان خلخال واقع شده و در محدوده شهر هشتمین است. این حوضه بین مختصات طول جغرافیایی  $48^{\circ}22'03''$  تا  $48^{\circ}33'35''$  و عرض جغرافیایی  $37^{\circ}15'00''$  تا  $37^{\circ}27'30''$  قرار گرفته است (شکل ۱).

**انتخاب عوامل موثر:** بر اساس پراکنش و خصوصیات زمین‌لغزش‌های حوضه سقزچای، ده متغیر شامل جهات جغرافیایی دامنه‌ها، درجه شیب، سنگ‌شناسی، کاربری



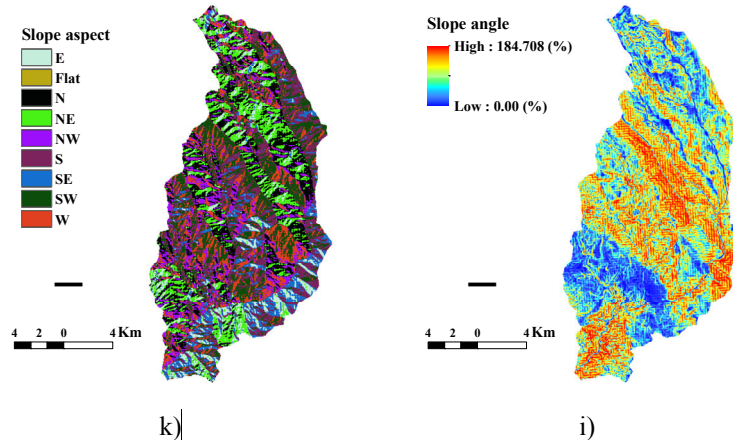
شکل ۱- موقعیت حوضه مورد مطالعه در استان اردبیل

Fig. 1. Location map of study area in Ardabil Province



شکل ۲- عوامل موثر در وقوع زمین لغزش‌های حوضه: (a) سنگ‌شناسی، (b) فاصله از گسل‌ها، (c) بیشینه شتاب افقی زمین، (d) فاصله از رودخانه‌ها، (e) مجموع بارندگی سالانه، (f) کاربری اراضی، (g) فاصله از مناطق مسکونی، (h) فاصله از راه‌ها

Fig. 2. Landslide conditioning factor maps in basin: a) Lithology, b) Distance to fault, c) Peak ground acceleration, d) Distance to stream network e) Average annual precipitation, f) Land-use, g) Distance to settlement area, h) Distance to roads



ادامه شکل ۲ k) جهات جغرافیایی دامنه‌ها و i) شیب دامنه‌ها  
**Fig. 2. Continued k) slope aspect and i) slope angle**

$$(1) \quad \text{بارندگی} = 471.162 - (X \times 4.81) + (Y \times 0.002) + (Z \times 0.063)$$

در این رابطه،  $X$  طول جغرافیایی (درجه)،  $Y$  عرض جغرافیایی (درجه) و  $Z$  ارتفاع (متر) است.

نقشه پراکنش زمین‌لغزش، یک داده ورودی ضروری برای مدلسازی زمین‌لغزش است، زیرا مکان و محدوده های دقیق زمین‌لغزش می‌تواند منجر به روشن شدن روابط بین عوامل موثر و وقوع زمین‌لغزش شود (Dou et al., 2020). نقشه پراکنش و شناسنامه‌ای زمین‌لغزش‌ها با استفاده از تفسیر عکس‌های هوایی و بر اساس کار میدانی گسترده تهیه و لایه مربوط به متغیر وابسته به صورت زمین‌لغزش و بدون زمین‌لغزش استخراج شد. داده‌های متغیرهای مستقل گسسته و پیوسته و متغیر وابسته طبقه‌بندی شده، به صورت یک فایل ASCII و در قالب پیکسل‌های  $50 \times 50$  متر، ذخیره و جهت انجام تجزیه آماری به نرم‌افزار SPSS 26 انتقال داده شد.

قبل از اجرای مدل‌ها و به منظور تجزیه و تحلیل مقدماتی داده‌های ورودی، فراوانی پیکسل‌های لغزشی و غیرلغزشی در هر طبقه از عوامل موثر به صورت مشاهده شده و پیش‌بینی شده، مورد مقایسه قرار گرفتند. به منظور ارزیابی تاثیر رده‌های عوامل موثر در وقوع زمین‌لغزش‌ها از طریق مقایسه فراوانی پیکسل‌های مشاهده شده و پیش‌بینی شده، تمام متغیرهای ده عامل رده‌های مختلف طبقه‌بندی شدند.

بر اساس نقشه رقومی ارتفاعی به دست آمده از نقشه های توپوگرافی  $1:25000$ ، لایه‌های درجه و جهات شیب استخراج شد. از نقشه زمین‌شناسی  $1:25000$ ، لایه‌های واحدهای سنگ‌شناسی و فاصله از گسل‌های اصلی حوضه، استخراج شد. در این پژوهش، داده‌های مربوط به نوع پوشش گیاهی و کاربری زمین، از نقشه‌های توپوگرافی و تصاویر ماهواره‌ای لندست ۸ سال ۲۰۱۸ استخراج و با بررسی‌های صحرایی، اصلاح و تکمیل شد. زلزله، به عنوان یک عامل تحریک‌کننده در وقوع زمین‌لغزش‌ها در نظر گرفته می‌شود که برای تحلیل شبه استاتیکی آن، لایه بیشینه شتاب افقی زمین، در زمان زلزله تهیه شد (Zhang et al., 2013؛ Xie et al., 2018).

لایه‌های مربوط به فاصله از جاده‌ها و مناطق مسکونی، نیز با استفاده از نقشه‌های توپوگرافی تهیه شد. مناطق مسکونی، همان محدوده‌های روستایی و شهری در حوضه هستند. راه‌های آسفالتی و شوسه مواصلاتی بین روستاهای حوضه در ترسیم نقشه حریم جاده‌ها مد نظر قرار گرفتند. برای تعیین میانگین مجموع بارندگی سالانه از رابطه (۱) استفاده شد و نقشه همباران  $1:25000$  تهیه شد (Hemmati et al., 2007). در محاسبه رابطه (۱)، از داده‌های ۵۸ ایستگاه باران‌سنجی استفاده شده است. داده‌های ایستگاه‌ها، در یک دوره ۲۰ ساله مورد استفاده قرار گرفته‌اند.



**روش شبکه‌های عصبی مصنوعی:** به منظور پیش‌بینی حساسیت به زمین لغزش، از روش غیرخطی شبکه عصبی به نام پرسپترون چند لایه<sup>۱</sup>، استفاده شد. شبکه پرسپترون چند لایه مجموعه‌ای از نرون‌های پایه است که در سه لایه قرار می‌گیرند. این سه لایه، با نام‌های لایه ورودی، لایه پنهان و لایه خروجی شناخته می‌شوند (شکل ۳). شبکه پرسپترون چند لایه، یک شبکه با ساختار رو به جلو<sup>۲</sup> است و از روش پس‌انتشار<sup>۳</sup> برای یادگیری شبکه استفاده می‌کند (Hagan et al., 2014).

**روش رگرسیون لجستیک:** رگرسیون لجستیک، یک روش مدلسازی ریاضی است که در این جا برای محاسبه احتمال وقوع زمین لغزش به کار برده شده است (Menard, 2002؛ Yesilnacar and Topal, 2005). در این روش، هدف اصلی پیدا کردن تابعی است که رابطه بین وجود و عدم وجود زمین لغزش (متغیر وابسته) با مجموعه‌ای از پارامترهای مستقل (عوامل وقوع زمین لغزش) را به بهترین وجه نشان دهد (Ayalew et al., 2005). مدلسازی با ورود متغیرهای پیوسته و گسسته شروع می‌شود. در این تحلیل، سه متغیر مستقل واحدهای سنگ‌شناسی، کاربری اراضی و جهات جغرافیای طبقه‌بندی شده هستند. به منظور، تحلیل آماری و مقایسه طبقات مختلف این سه متغیر، متغیرهای مجازی یا ساختگی<sup>۴</sup> توسط نرم‌افزار تولید می‌شود.

تعداد متغیرهای مجازی، همیشه یکی کمتر از سطوح متغیر طبقه‌ای است. برای مثال، متغیر طبقه‌ای واحدهای سنگ‌شناسی با ۱۱ طبقه مختلف، به ۱۰ متغیر مجازی با مقدارهای صفر و یک تبدیل شده است. در این مدل، یک متغیر وابسته دودویی (۰ و ۱) با احتمال  $\pi_i$ ، در نظر گرفته می‌شود که برای  $i$  امین پیکسل، رابطه (۳) را می‌توان به کار برد (Wahono, 2010؛ Grozavu et al., 2012).

عامل سنگ‌شناسی بر اساس نوع و ترکیب سنگ‌های اصلی واحدها یا سازندهای زمین‌شناسی، به ۱۱ طبقه تقسیم شد. عامل کاربری اراضی، برحسب نوع استفاده از زمین به پنج گروه تقسیم شد. عامل جهات جغرافیایی، بر اساس هشت جهت اصلی و اراضی مسطح که رو به جهت خاصی نیستند به نه طبقه تقسیم شدند. طبقه‌بندی بقیه عوامل، بر اساس تقسیم‌بندی‌هایی که در منابع موجود صورت گرفته (Li et al., 2021; Ling et al., 2022) و بر مبنای شرایط منطقه و پراکنش زمین لغزش‌ها، انجام گرفته است. فراوانی پیکسل‌های لغزشی و غیرلغزشی به عنوان مقادیر مشاهده شده در رده‌های تمام عوامل، از لایه اطلاعاتی مربوطه، استخراج شد. برای محاسبه مقادیر احتمالی یا پیش‌بینی شده برای هر کدام از طبقات، عوامل موثر از رابطه (۲) استفاده شده است (Norusis, 2006).

که در آن،  $P_i$  فراوانی پیش‌بینی شده برای پیکسل‌های درگیر زمین لغزش در هر طبقه از عوامل مورد نظر، مجموع پیکسل‌های زمین لغزشی و پیکسل‌های بدون زمین لغزش در هر طبقه از عامل،  $n$  فراوانی پیکسل‌های درگیر زمین لغزش در کل واحدهای هر عامل و  $N$  مجموع فراوانی پیکسل‌های دارای زمین لغزش و بدون زمین لغزش در تمام طبقات هر عامل است. مقایسه مقادیر مثبت و منفی باقی‌مانده حاصل از تفاصل این دو گروه فراوانی، نشان دهنده میزان تاثیر رده‌های هر عامل در وقوع زمین لغزش بوده و به صورت نمودار نشان داده شده است.

**داده‌های ورودی:** در این پژوهش، ۷۰ درصد از پیکسل‌ها برای برآورد احتمال وقوع زمین لغزش و ۳۰ درصد باقیمانده، به منظور ارزیابی و اعتبارسنجی مدل به طور اتفاقی انتخاب شدند (Bravo-López et al., 2022). از مجموعه داده‌ها، ۷۸۱۲۰ پیکسل دارای زمین لغزش و بدون زمین لغزش به طور اتفاقی برای تحلیل رگرسیون لجستیک انتخاب و تعداد ۳۳۵۵۳ پیکسل دارای زمین لغزش نیز برای سنجش صحت مدل نگه داشته شدند.

<sup>1</sup> Multilayer Perceptron (MLP)

<sup>2</sup> Feed forward

<sup>3</sup> Back propagation

<sup>4</sup> Dummy

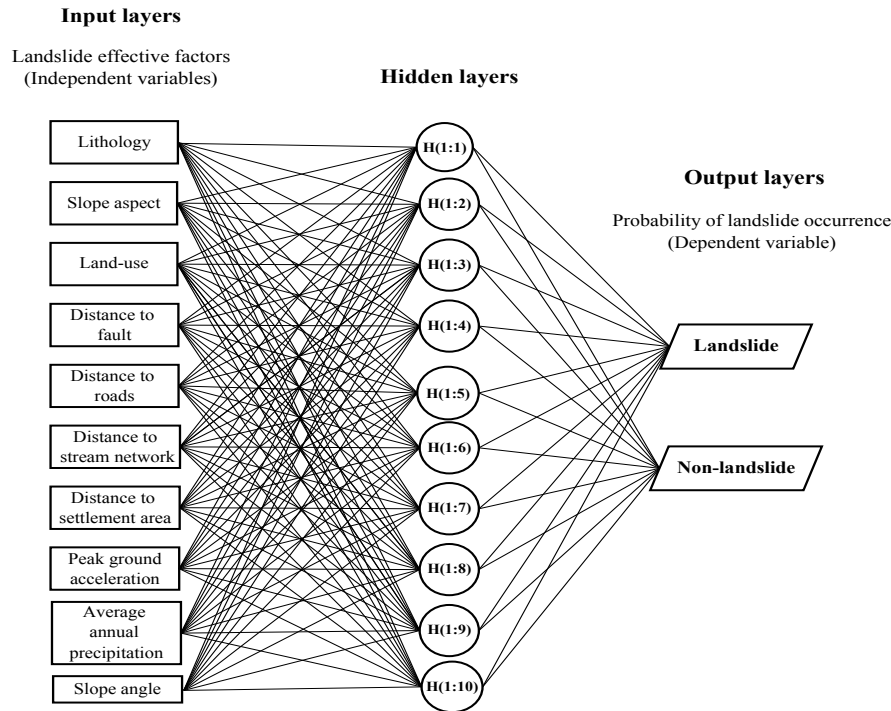
$i$  امین پیکسل برای  $z_i$  زمین متغیر،  $b_j$   $z_j$  زمین ضریب و  $p$  تعداد متغیرهای مستقل است. اجرای این مدل، با استفاده از روش گام به گام رو به جلو ( Forward Maximum Likelihood Method)، به روش حداکثر درست‌نمایی ( Maximum Likelihood Method) صورت گرفت.

$$P(Y=1|X=x)=f(z_i)=\pi_i=\frac{1}{1+e^{-z_i}} \quad (3)$$

که در آن،  $\pi_i$  احتمال وقوع زمین‌لغزش در  $i$  امین پیکسل و  $z_i$  تابعی از متغیرهای مستقل است (رابطه ۴).

$$z_i=b_0+b_1x_{1i}+b_2x_{2i}+\dots+b_px_{pi} \quad (4)$$

که در آن،  $x_{ij}$   $j$  امین متغیر مستقل (عوامل موثر) برای  $i$  امین پیکسل، به عبارت دیگر، مقدار مشاهده شده



شکل ۳- شبکه عصبی پرسپترون چند لایه  
Fig. 3. The multilayer perceptron neural network

$$Sensitivity = \frac{n_{tp}}{n_{tp} + n_{fn}} \quad (5)$$

که در آن،  $n_{tp}$  تعداد پیکسل‌های دارای زمین‌لغزش که درست پیش‌بینی شده است و  $n_{fn}$  تعداد پیکسل‌های بدون زمین‌لغزش که اشتباه پیش‌بینی شده است. قدرت درست‌نمایی و یا وضوح‌سازی<sup>۳</sup> مدل نیز بر اساس درصد پیکسل‌های درست طبقه‌بندی شده که فاقد زمین‌لغزش هستند، نشان داده می‌شود (رابطه ۶).

$$Specificity = \frac{n_{tm}}{n_{tm} + n_{fp}} \quad (6)$$

که در آن،  $n_{tm}$  تعداد پیکسل‌های بدون زمین‌لغزش که درست پیش‌بینی شده است و  $n_{fp}$  تعداد پیکسل‌های دارای زمین‌لغزش که اشتباه پیش‌بینی شده است. برای

ارزیابی دقت مدل: منحنی<sup>۱</sup> ROC، روش بسیار مفیدی در ارزیابی مدل‌های طبقه‌بندی کننده مناطق به گروه‌های دارای زمین‌لغزش و بدون زمین‌لغزش است (Mathew et al., 2009). سطح زیر منحنی، میزان فزونی احتمال انتخاب مثبت را نسبت به انتخاب منفی نشان می‌دهد. اگر سطح زیر منحنی در یک مدل، برابر یک باشد، بهترین و کامل‌ترین پیش‌گویی را انجام خواهد داد. در این روش، درصدی از پیکسل‌های دارای زمین‌لغزش که توسط مدل به درستی پیش‌بینی شده‌اند حساسیت<sup>۲</sup> مدل نامیده می‌شوند (رابطه ۵).

<sup>1</sup> Receiver Operating Characteristic (ROC)

<sup>2</sup> Sensitivity

<sup>3</sup> Specificity

رودخانه‌های اصلی در منطقه درگیر زمین لغزش هستند، در فواصل دورتر این مساحت به ۸/۶ درصد تقلیل می‌یابد (شکل d۴). حدود ۱۳/۲۷ درصد از پیکسل‌های با میزان بارندگی سالانه ۳۱۰ تا ۳۳۰ میلی‌متر و ۳۸/۸۴ درصد از مناطق با بارندگی سالیانه ۳۷۰ تا ۴۱۰ میلی‌متر، درگیر زمین لغزش هستند که در هر دو رده، فراوانی زمین لغزش‌های اتفاق افتاده با میزان پیش‌بینی شده اختلاف معنی‌دار افزایشی نشان می‌دهد (شکل f۴).

کاربری اصلی اراضی در حوضه، زراعت، مرتع، جنگل و مسکونی است. بیشترین مساحت زمین لغزش‌ها نسبت به کل مساحت اراضی با ۴۸ و ۲۳/۵۴ درصد به ترتیب به اراضی مسکونی و زراعی اختصاص دارد. مناطق جنگلی و مرتعی نیز با توجه به تخریب‌های انجام گرفته در سال‌های گذشته به‌طور چشمگیری درگیر زمین لغزش هستند (شکل f۴). به فاصله ۵۰۰ متری از مناطق مسکونی در حوضه، تعداد پیکسل‌های درگیر زمین لغزش از تعداد پیش‌بینی شده بیشتر بوده و اختلاف معنی‌دار دارند (شکل g۴).

حداقل ۲۲ درصد از مساحت پهنه‌های با فاصله ۵۰۰ متری از مناطق مسکونی، درگیر زمین لغزش هستند در حالی که در فاصله دورتر، این درصد به ۴/۵ کاهش می‌یابد. در این حوضه، تا فاصله ۲۰۰ متری از جاده‌ها و راه‌ها حدود ۱۶ درصد از مساحت کل منطقه درگیر زمین لغزش هستند، اما در فاصله دورتر، حداکثر ۸/۵ درصد از مساحت پهنه‌ها، زمین لغزشی است (شکل h۴). باقیمانده‌های مثبت حاصل از تفاضل تعداد پیکسل‌های درگیر زمین لغزش و پیکسل‌های پیش‌بینی شده برای دامنه‌های رو به شمال و شمال شرق نشان‌دهنده تمرکز زمین لغزش‌ها در این دامنه‌ها است که به ترتیب ۱۴/۲۰ و ۱۲/۶۹ درصد از مساحت دامنه‌های رو به این جهات، درگیر زمین لغزش هستند (شکل k۴). در منطقه مورد مطالعه، ۷۳/۷۸ درصد از نسبت پیکسل‌های زمین لغزشی به کل پیکسل‌ها در سه رده شیبی II، III و IV قرار می‌گیرند (شکل i۴).

تکمیل مرحله ارزیابی و تعیین دقت مدل‌ها از شاخص دیگری تحت عنوان، مجذور میانگین مربع خطا<sup>۱</sup> استفاده شده است (رابطه ۷). مقادیر پایین این شاخص نشان‌دهنده دقت بالای برآوردها است.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Obs-Pre)^2}{n}} \quad (7)$$

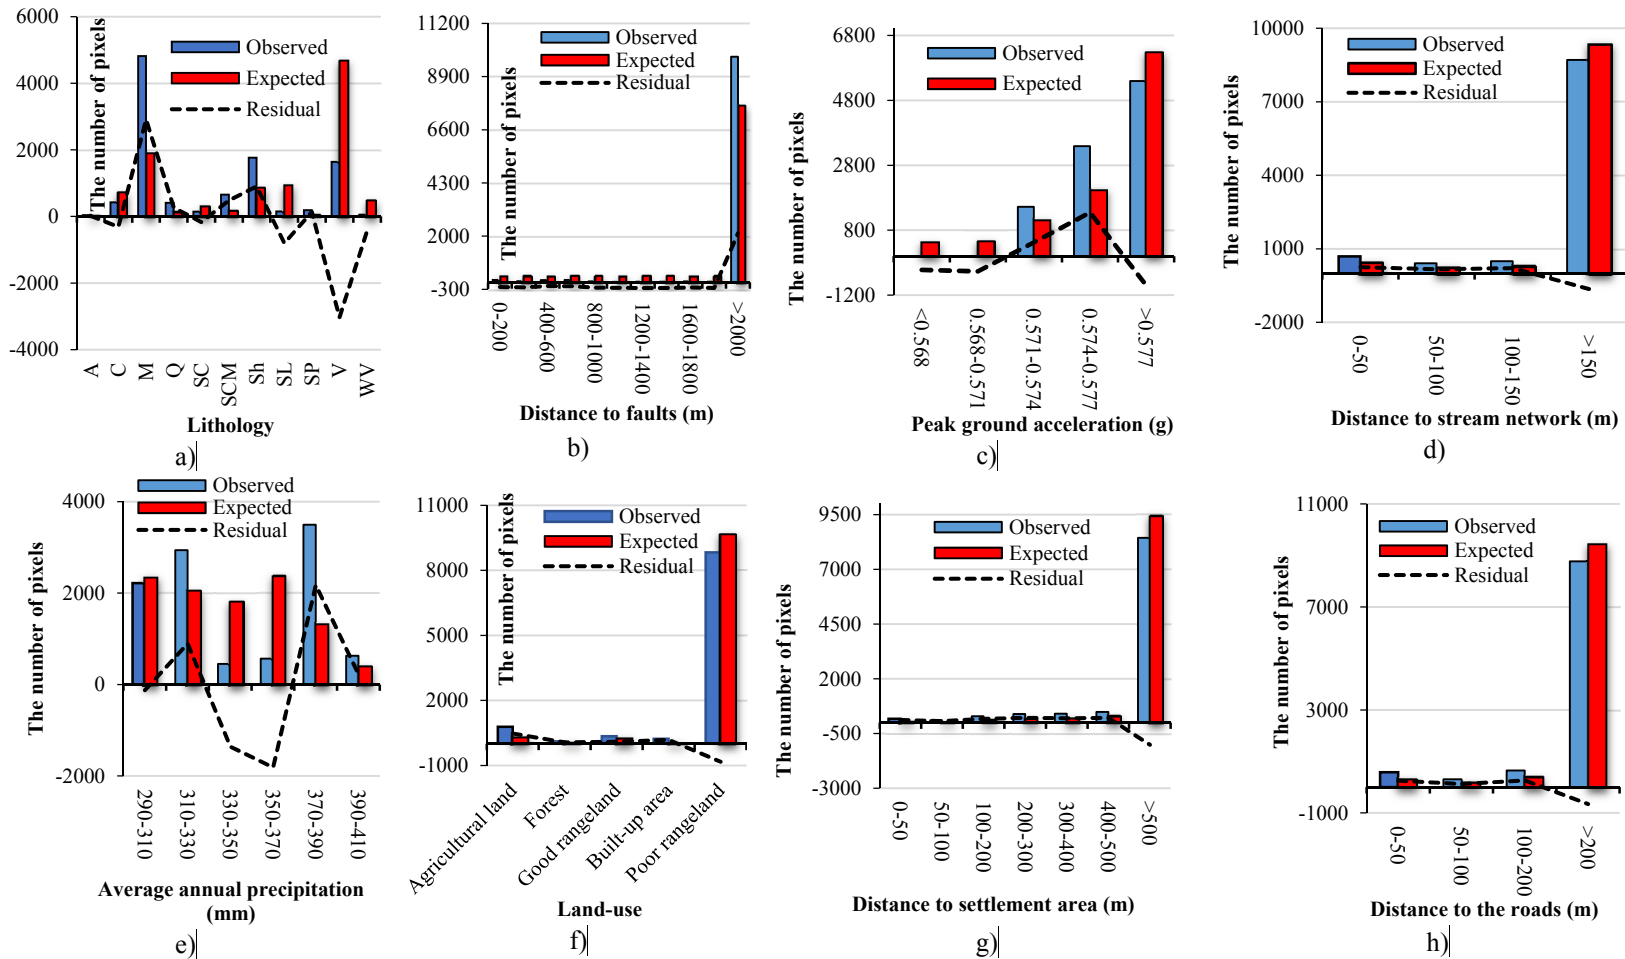
که در آن، *Obs* مقادیر مشاهده شده، *Pre* مقادیر پیش‌بینی شده و *n* تعداد کل داده‌ها در هر مرحله آموزشی و ارزیابی است.

## نتایج و بحث

**عوامل موثر:** مقایسه فراوانی‌هایی مشاهده شده و احتمالی زمین لغزش‌ها و باقی‌مانده حاصل از تفاضل آن‌ها نشان می‌دهد که ۷۰/۷ درصد از مساحت مناطق زمین لغزشی در سنگ‌های رسوبی رس‌دار شامل واحدهای مارنی، شیستی و دگرسانی‌ها واقع شده است (شکل a۴). در فاصله دو کیلومتری از گسل‌های اصلی منطقه، تعداد پیکسل‌های زمین لغزشی پیش‌بینی شده بیشتر از پیکسل‌های زمین لغزشی مشاهده شده است که نشان می‌دهد تاثیر گسل‌های شناسایی شده از طریق خردشدگی نبوده است (شکل b۴).

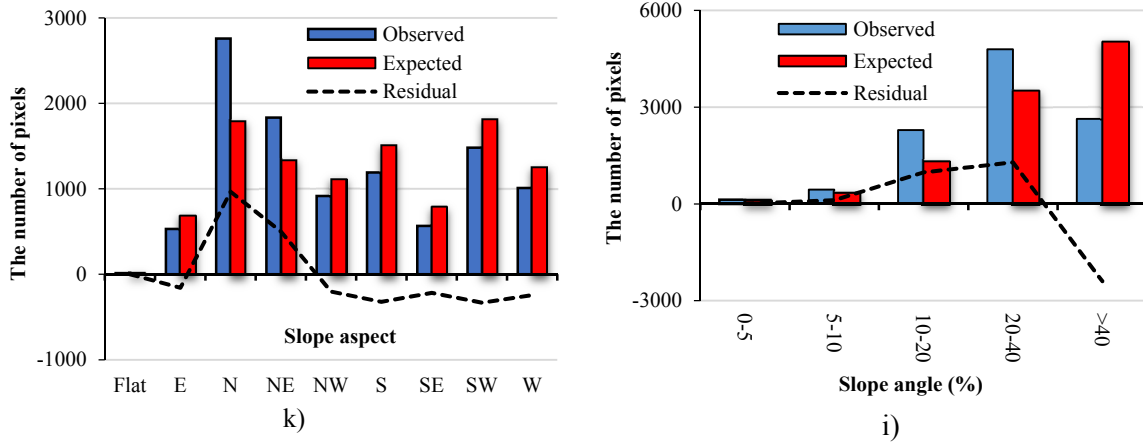
تاثیر گسل‌های منطقه در وقوع زمین لغزش‌ها می‌تواند از طریق نفوذ محلول‌های هیدروترمال و گسترش پهنه‌های دگرسانی بوده باشد. افزایش وقوع زمین لغزش‌ها در فاصله بیشینه شتاب افقی زمین، برابر ۰/۵۷۱ تا ۰/۵۷۷ (شکل g۴) نیز، نشان می‌دهد که غیر از حرکات زلزله وجود عواملی مانند واحدهای سنگ‌شناسی نیز لازم است (شکل c۴). چون با افزایش میزان بارندگی احتمال وقوع زمین لغزش، به‌صورت یکنواخت افزایش نمی‌یابد لذا، نمی‌توان وقوع لغزش‌ها را به‌طور مستقیم با افزایش میزان بارندگی توجیه نمود، بلکه تاثیر میزان رواناب و تغییرات سطح آب‌های زیرزمینی در وقوع زمین لغزش‌ها با تغییر ویژگی‌های مکانیکی سنگ‌ها و خاک‌های منطقه نیز می‌تواند دخالت داشته باشد. حدود ۱۵/۵ درصد از مساحت پهنه‌های با فاصله صفر تا ۱۵۰ متری از بستر

<sup>1</sup> Root Mean Square Error (RMSE)



شکل ۴- عوامل موثر در وقوع زمین لغزش‌های حوضه: (a) واحدهای سنگ‌شناسی، (b) فاصله از گسل‌ها، (c) بیشینه شتاب افقی زمین، (d) فاصله از رودخانه‌ها، (e) مجموع بارندگی سالانه، (f) کاربری اراضی، (g) فاصله از مناطق مسکونی، (h) فاصله از راه‌ها

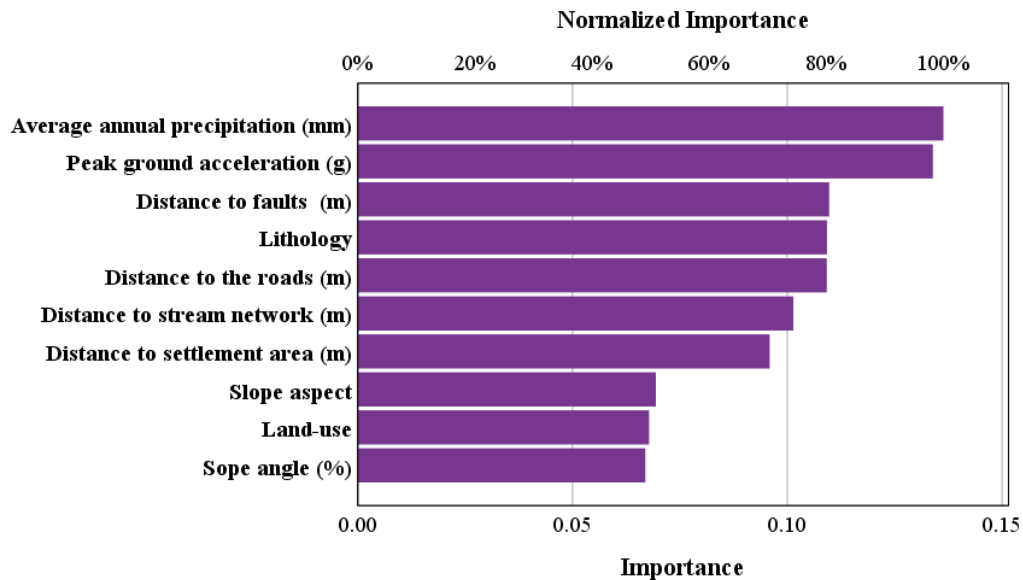
Fig. 4. Landslide conditioning factor maps in basin: a) Lithology, b) Distance to fault, c) Peak ground acceleration, d) Distance to stream network e) Average annual precipitation, f) Land-use, g) Distance to settlement area, h) Distance to roads



ادامه شکل ۴ k) جهات جغرافیایی و i) درصد شیب دامنه‌ها  
Fig. 4 Continued k) slope aspect and i) slope angle

تعداد متغیرهای کمکی به علاوه تعداد کل سطوح عامل یعنی ۳۲ عدد است. میزان اهمیت نسبی عوامل موثر در زمین لغزش‌های منطقه و مقادیر نرمال سازی شده آن‌ها، در نمودار شکل (۵) نشان داده شده است.

تحلیل حساسیت به زمین لغزش به روش شبکه‌های عصبی مصنوعی: مدل با ورود ده متغیر مستقل و یک متغیر وابسته، به صورت وجود و عدم وجود زمین لغزش، اجرا شد. تعداد واحدهای قرار گرفته در لایه ورودی برابر



شکل ۵- اهمیت عوامل موثر در وقوع و یا عدم وقوع زمین لغزش بر اساس مدل شبکه‌های عصبی مصنوعی  
Fig. 5. The importance of effective factors in occurrence or non-occurrence of landslides based on the artificial neural network model

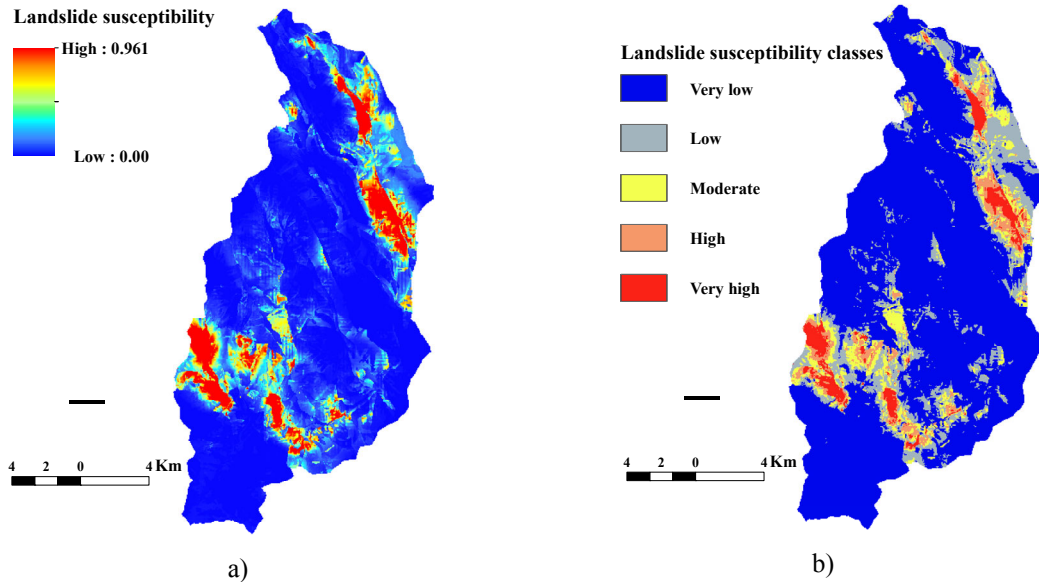
راه‌ها (۰/۱۰۹)، فاصله از رودخانه‌ها (۰/۱۰۱)، فاصله از مناطق مسکونی (۰/۰۹۶)، جهات جغرافیایی دامنه‌ها (۰/۰۶۹)، کاربری اراضی (۰/۰۶۸) و درصد شیب دامنه‌ها (۰/۰۶۷) به ترتیب در مدلسازی حساسیت به زمین لغزش به روش شبکه‌های عصبی مصنوعی، اهمیت دارند.

عوامل تشدیدکننده زمین لغزش‌ها، شامل میانگین بارندگی سالانه (۰/۱۳۶) و بیشینه شتاب افقی زمین (۰/۱۳۴)، بیشترین تاثیر را بر چگونگی پیش‌بینی احتمال وقوع زمین لغزش‌ها دارند. عوامل فاصله از گسل‌ها (۰/۱۱۰)، واحدهای سنگ‌شناسی (۰/۱۰۹)، فاصله از

شکست طبیعی (Natural breaks)، است. بر مبنای این طبقه‌بندی، ۸۵/۷ درصد از منطقه در پهنه‌های با حساسیت کم و بسیار کم قرار می‌گیرد. در ۶/۶ درصد از منطقه، احتمال حساسیت به زمین‌لغزش متوسط و در ۷/۷ درصد، حساسیت بالا و بسیار بالا برای وقوع زمین‌لغزش وجود دارد.

بنابراین، تمامی ده عامل در مدل‌سازی به روش شبکه‌های عصبی مصنوعی به کار گرفته شدند. نتایج به دست آمده نشان داد که احتمال وقوع زمین‌لغزش در فاصله ۰/۰۰ تا ۰/۹۶۱ تغییر می‌نماید.

احتمال وقوع زمین‌لغزش برای هر پیکسل به صورت تصویری در شکل ۶a، نشان داده شده است. نقشه شکل ۶b، مربوط به درجات حساسیت به زمین‌لغزش به روش



شکل ۶- a) نقشه حساسیت به زمین‌لغزش حوضه بر اساس احتمال وقوع زمین‌لغزش‌ها به روش شبکه عصبی مصنوعی، b) نقشه درجه حساسیت به زمین‌لغزش بر اساس روش شکست طبیعی

Fig. 6. a) Landslide susceptibility map based on the probability of landslides occurrence using artificial neural network, b) Landslide susceptibility classes map based on natural break method

درست پیش‌بینی شده است. به طور کلی، ۹۳/۵ درصد از موارد آموزشی به درستی و باقیمانده یعنی ۶/۵ درصد از موارد به اشتباه طبقه‌بندی شده‌اند (جدول ۱) که حاکی از عملکرد بسیار عالی مدل است.

**دقت مدل:** در بین پیکسل‌هایی که برای مدل‌سازی استفاده شد، ۳۳۲۲ مورد از ۷۱۷۱ که درگیر زمین‌لغزش بوده‌اند، به درستی طبقه‌بندی شده‌اند. همچنین، ۶۹۷۳۶ پیکسل از ۷۰۹۴۹ پیکسلی که فاقد زمین‌لغزش بودند،

جدول ۱- میزان موفقیت مدل شبکه‌های عصبی مصنوعی در نمونه‌های آزمایشی و ارزیابی

Table 1. The success rate of the artificial neural network model in training and testing samples

Sample	Pixels	Predicted		
		No landslide	Landslide	Percentage correct
Training	No landslide	69736	1213	93.3
	Landslide	3849	3322	46.3
	Overall percentage	94.2	5.8	93.5
Testing	No landslide	29880	540	98.2
	Landslide	1724	1409	45
	Overall percentage	94.2	5.8	93.3


یافته است که این کاهش مقادیر این آماره، با پیشرفت اجرای مدل نشان‌دهنده تناسب آن است. مقادیر ضرایب معادله لوجیت، عرض از مبدا، شاخص والد، سطح معنی دار و شانس عضویت در گروه پیکسل‌های زمین‌لغزشی و بدون زمین‌لغزش در جدول (۲)، نشان داده شده است. مقادیر آماره والد و سطح معنی‌داری مربوط به آزمون نشان می‌دهد که تنها سه سطح از عامل جهات جغرافیایی در مدل رگرسیون لجستیک، بی‌اثر هستند.

با تخمین ثابت و ضرایب مربوط به متغیرهای مستقل در تحلیل رگرسیون لجستیک، در مرحله بعد مقادیر احتمال برای تمام پیکسل‌های منطقه بر اساس مقادیر متغیرهای مستقل محاسبه شد. این برآورد، بر اساس تابع تعریف شده (رابطه ۳) انجام گرفت. نتیجه به صورت یک لایه رستری نشان داده شد که در آن به هر سلول مقادیر احتمال تخمینی اختصاص یافته است و این احتمال بین صفر تا یک تغییر می‌نماید (شکل ۸a).

با درجه‌بندی حساسیت به زمین‌لغزش به روش شکست طبیعی، حوضه به پنج پهنه حساسیت تقسیم شد (شکل ۸b). در این درجه‌بندی، ۷۹/۹ درصد از منطقه مورد مطالعه در گروه با حساسیت پایین و بسیار پایین قرار گرفته است. پهنه‌های با حساسیت متوسط، ۱۰/۱ درصد از منطقه را به خود اختصاص داده است و ۱۰ درصد منطقه در پهنه‌های با درجه حساسیت بالا و بسیار بالا قرار می‌گیرد. جدول (۳)، میزان موفقیت مدل را در پیش‌گویی وقوع یا عدم وقوع زمین‌لغزش در هر پیکسل بعد از ورود متغیرهای مستقل نشان می‌دهد.

در گام دهم ورود مجموعه متغیرهای مستقل به مدل، ۹۱/۴ درصد از کل پیکسل‌های آموزشی و ۹۱/۳ درصد از پیکسل‌های ارزیابی به‌درستی پیش‌بینی شده‌اند که در مقایسه با ۵۰ درصد مدل صفر، بهبود بسیار خوبی است. در شکل (۹)، منحنی ROC مربوط به مدل اجرا شده در این پژوهش نشان داده شده است. سطح زیر منحنی، برابر ۰/۸۴۸ بوده و نشان می‌دهد که دقت پیش‌گویی مدل ۸۴/۸ درصد است که نتیجه بسیار خوبی برای پیش‌بینی است.

در منحنی ROC، سطح زیر منحنی<sup>۱</sup> در مدل تحلیل حساسیت به زمین‌لغزش، به روش شبکه‌های عصبی مصنوعی برابر ۰/۹۲۹ بوده و نشان‌دهنده دقت ۹۲/۹ درصدی مدل است (شکل ۷) که نتیجه بسیار عالی در ارزیابی حساسیت به زمین‌لغزش مدل مورد استفاده محسوب می‌شود (Sdao et al. 2013; Polykretis et al., 2015).



شکل ۷- منحنی ROC برای ارزیابی دقت مدل شبکه‌های عصبی مصنوعی (۰: بدون زمین‌لغزش، ۱: با زمین‌لغزش)

Fig. 7. The ROC curve for the artificial neural networks model (0: no landslide, 1: with landslide)

### تحلیل حساسیت به زمین‌لغزش به روش رگرسیون

لجستیک: این روش، با مدل بدون متغیر مستقل شروع شد و با اضافه کردن متغیرها در قدم دهم خاتمه یافت. در هر گام، متغیر مستقل که مقدار سطح معنی‌دار آن از مقدار تعیین شده (۰/۰۵) کم‌تر بود، وارد مدل شده است. در گام آخر مدل، متغیرهایی که مقادیر معنی‌دار آنها بزرگ‌تر از ۰/۰۵ است از تحلیل خارج شدند. در انتخاب متغیرها، تغییرات در لگاریتم درست‌نمایی<sup>۲</sup> قابل اعتمادتر از تغییرات آماره والد<sup>۳</sup> است (Davis and Ohlmacher, 2002). مقدار متغیر لگاریتم درست‌نمایی در گام اول از ۴۰۳۴۳ به ۳۵۸۲۲ در گام دهم، کاهش

<sup>1</sup> The Area Under Curve (AUC)

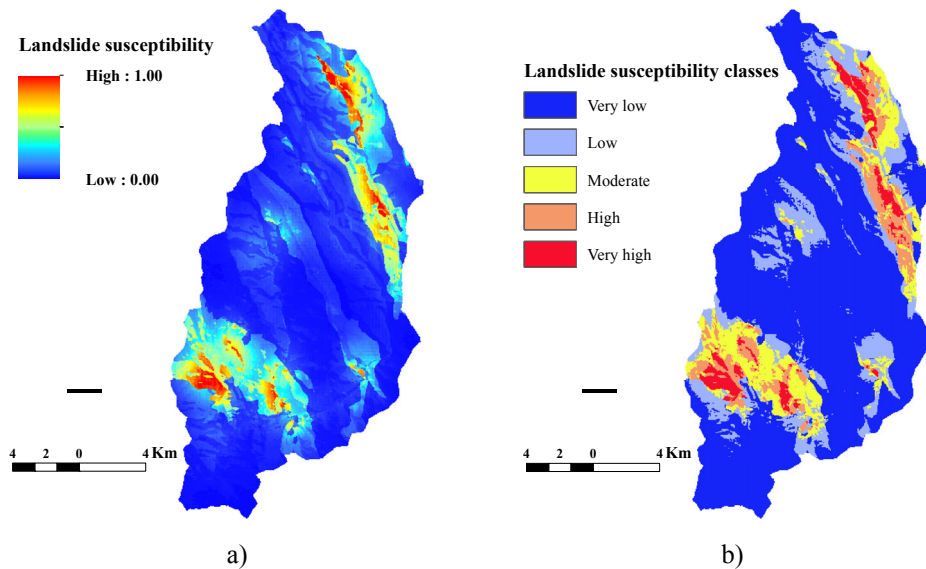
<sup>2</sup> Log-likelihood

<sup>3</sup> Statistic wald

جدول ۲- متغیرها و ضرایب آنها در گام نهایی (گام دهم)، متغیرهای گسسته واحدهای سنگ‌شناسی، جهات جغرافیایی و کاربری اراضی به صورت متغیرهای ساختگی (مجازی)

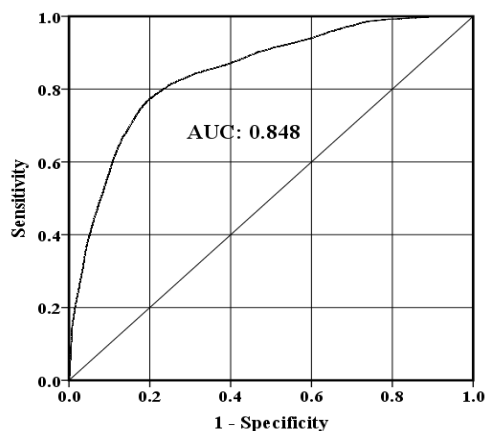
**Table 2.** Variables and their coefficients in the final step (tenth step), categorical variables of lithology, slope aspect and land-use are dummy variables

Independent variables	B	Wald	Significant value	Odds ratio Exp(B)
Lithology	-	2912.264	0.000	-
Q: Alluvial and collovial deposits	1.247	86.214	0.000	3.480
A: Altered zones	1.322	31.729	0.000	3.751
SCM: Sandstone, conglimerate and marl	1.532	135.541	0.000	4.629
SL: Sandy to silty limestone	-0.503	12.098	0.001	0.605
V: Volcanic rocks	-0.336	8.960	0.003	0.715
SP: Phylite and metamorphic rocks	2.137	200.651	0.000	8.476
C: Limestone	0.437	12.651	0.000	1.547
Sh: Schist and shale	1.854	277.772	0.000	6.383
M: Marl and claystone	1.349	144.921	0.000	3.852
WV: Weathered and brecciated extrusive rocks	-0.885	12.609	0.000	0.413
Slope aspect	-	797.736	0.000	-
Flat	-0.175	0.181	0.670	0.839
E	0.135	2.644	0.104	1.144
NE	0.437	40.649	0.000	1.548
N	0.352	28.337	0.000	1.421
NW	-0.479	41.856	0.000	0.619
W	-0.529	52.073	0.000	0.589
SW	-0.510	54.609	0.000	0.600
S	-0.429	36.568	0.000	0.651
Land-use	-	188.098	0.000	-
Agricultural land	-0.708	124.897	0.000	0.492
Forest	0.770	28.409	0.000	2.160
Good rangeland	0.247	8.380	0.004	1.280
Poor rangeland	0.257	3.984	0.046	1.293
Distance to stream network (m)	-0.001	708.689	0.000	0.999
Distance to faults (m)	0.00023	648.895	0.000	1.000
Peak ground acceleration (g)	0.29	311.448	0.000	1.337
Mean annual precipitations (mmyr <sup>-1</sup> )	-0.025	259.386	0.000	0.975
Distance to road (m)	-0.007	50.939	0.000	0.993
Distance to settlement area (m)	0.00028	205.904	0.000	1.000
Slope gradient (%)	0.00039	317.110	0.000	1.000
Constant	-161.094	319.481	0.000	0.000



شکل ۸- (a) نقشه حساسیت به زمین لغزش در حوضه بر اساس احتمال وقوع به روش رگرسیون لجستیک، (b) نقشه درجه حساسیت به زمین لغزش  
**Fig. 8.** a) Landslide susceptibility map based on the probability of landslides occurrence using logistic regression, b) Landslide susceptibility classes map based on natural break method





شکل ۹- منحنی ROC برای مدل رگرسیون لجستیک  
**Fig. 9.** The ROC curve for logistic regression model

شاخص مقادیر مجذور میانگین خطا، برای ارزیابی نتایج مدل‌ها برای داده‌های آموزشی، ارزیابی و کل، در جدول ۴، نشان داده شده است. مقادیر مجذور میانگین خطای تمام داده‌ها در هر دو مدل، پایین بوده و بیانگر دقت خوب پیش‌بینی وقوع زمین لغزش‌ها است (Ajim et al., 2021).

بر اساس مقادیر این شاخص، می‌توان نتیجه گرفت که مدل شبکه‌های عصبی مصنوعی هم در مورد داده‌های آموزشی و هم ارزیابی نسبت به رگرسیون لجستیک عملکرد خوبی دارد.

جدول ۳- میزان موفقیت مدل رگرسیون لجستیک در گروه‌بندی پیکسل‌ها به دارای لغزش و بدون لغزش

**Table 3.** The success rate of the logistic regression model in training and testing samples

Observed	Predicted					
	No landslide	Landslide	Percentage correct	No landslide	Landslide	Percentage correct
No landslide	70237	712	99	30126	294	99
Landslide	5988	1183	16.5	2632	501	16
Overall percentage			91.4			91.3

جدول ۴- مجذور میانگین مربع خطا به منظور ارزیابی دقت مدل شبکه عصب مصنوعی و رگرسیون

**Table 4.** Root Mean Square Error (RMSE) to evaluate the accuracy of artificial neural network and logistic regression models

Parameter	Artificial neural networks			Logistic regression		
	Training sample	Testing sample	Overall	Training sample	Testing sample	Overall
Root Mean Square Error (RMSE)	0.2232	0.2267	0.2243	0.2601	0.2622	0.2607

از عوامل اصلی در افزایش احتمال وقوع زمین لغزش‌ها در نظر گرفته می‌شود (Chen et al., 2015; Meinhardt et al., 2015; Zhang, 2021).

با توجه به نتایج به دست آمده از تحلیل عوامل موثر، می‌توان پوشش گیاهی زراعی و ایجاد تغییرات در پوشش مرتعی و جنگلی منطقه را از عواملی تشدید فعالیت زمین لغزش‌ها در سال‌های گذشته دانست (John et al., 2006). همچنین، تاثیر پوشش گیاهی در پایداری شیب‌های منطقه به تغییر چسبندگی، زاویه اصطکاک درونی، وزن و فشار آب مغذی خاک‌ها نسبت داده می‌شود (Gómez and Kavzoglu, 2005). تاثیر مناطق مسکونی و احداث جاده‌های اصلی، در وقوع زمین لغزش‌های منطقه با کاهش مقاومت برشی لایه‌های زمین و با افزایش میزان آب نفوذی در اثر ایجاد تغییرات در مورفولوژی دامنه‌ها، حفاری‌ها و ترانشه‌برداری‌های مسیر

بر اساس نتایج به دست آمده از پژوهش، می‌توان نتیجه گرفت که حضور کانی‌های رسی در واحدهای سنگ‌شناسی منطقه را می‌توان به عنوان یکی از عوامل اصلی وقوع و فعالیت زمین لغزش‌ها دانست (Türköz and Tosun, 2011; Galeandro et al., 2014). میزان بارندگی در برخی از مناطق حوضه، به عنوان یکی از عوامل اصلی وقوع زمین لغزش به شمار می‌رود (Ling et al., 2022). عدم افزایش یکنواخت فراوانی زمین لغزش‌ها، با افزایش میزان بارندگی سالیانه نشان می‌دهد که میزان تاثیر بارندگی در ناپایداری دامنه‌ها به نوع و ترکیب واحدهای سنگ‌شناسی، میزان رواناب و تغییرات سطح آب‌های زیرزمینی نیز بستگی دارد (Uromeihy and MahdaviFar, 2000; Tian et al., 2017).

افزایش میزان بارندگی با افزایش دبی رودخانه‌ها و شدت یافتن فرسایش کنار رودخانه‌ای نیز، به عنوان یکی

مصنوعی با دقت ۸۰/۱۰ درصد، در پیش‌بینی زمین لغزش‌ها بهتر از مدل رگرسیون لجستیک با دقت ۷۷/۰۵ درصد است (Saro et al., 2016). در ارزیابی حساسیت به زمین‌لغزش در منطقه دره رودخانه سرچیو<sup>۲</sup> نیز، روش شبکه‌های عصبی مصنوعی با ۸۵ درصد دقت، نسبت به مدل رگرسیون لجستیک با دقت ۸۱ درصدی برتری دارد (Falaschi et al., 2009).

حساسیت به زمین‌لغزش، در بخشی از حوضه هراز با روش شبکه‌های عصبی مصنوعی تحلیل شده و نتایج به‌دست آمده برای داده‌های آموزشی و ارزیابی دقتی بالاتر از ۹۲ درصد را نشان می‌دهد که همچون نتایج پژوهش در حوضه سقزچای، بسیار رضایت‌بخش است (Sepah Vand et al., 2017). مقایسه روش شبکه‌های عصبی مصنوعی با روش رگرسیون لجستیک در پیش‌بینی روند تغییرات زمین‌لغزش در منطقه شمال قوچان نیز نشان داد، این روش با دقت ۹۶ درصدی نسبت به دقت ۸۶ درصدی رگرسیون لجستیک، بهترین عملکرد را دارد (Khosravi and Jamali, 2019).

نتایج به‌دست آمده از برخی مطالعات، برخلاف نتایج پژوهش اخیر بوده و در آن‌ها کارایی مدل رگرسیون لجستیک بهتر از شبکه‌های عصبی مصنوعی بوده است. از جمله ارزیابی حساسیت به زمین‌لغزش به پنج روش در شهر میزونامی<sup>۳</sup> ژاپن نشان می‌دهد که روش رگرسیون لجستیک با دقت ۷۸/۷ درصد، دقیق‌ترین مدل است، در حالی که روش شبکه‌های عصبی مصنوعی دقتی برابر ۷۳/۷ درصد داشته است (Wang et al., 2016). مقایسه پنج روش جدید در شهر بیجار در شرق استان کردستان، نیز نشان داد که روش رگرسیون لجستیک با دقت ۹۳/۲ درصدی، بهترین مدل برای ارزیابی حساسیت به زمین‌لغزش است.

همچنین، روش شبکه‌های عصبی نیز با دقت پیش‌بینی ۸۶ درصد، مدل بسیار خوبی برای پیش‌بینی احتمال وقوع زمین‌لغزش در منطقه معرفی شده است (Nhu et al., 2020). بنابراین، می‌توان نتیجه گرفت که

جاده‌ها قابل توجیه است (Ayalew and Yamagishi, 2005; Regmi et al., 2014).

بیش از ۴۴ درصد از زمین‌لغزش‌های منطقه در دامنه‌های رو به شمال و شمال شرق اتفاق افتاده‌اند. در این گروه از دامنه‌ها، نفوذ جبهه هوای خزری و افزایش بارندگی، باعث تغییر در میزان و جهت جریان رواناب، تراکم پوشش گیاهی، دما و رطوبت خاک شده و افزایش فراوانی زمین‌لغزش‌ها را سبب شده است (Chen and Chen, 2021).

مدل رگرسیون لجستیک، یک روش آماری پرکاربرد در ارزیابی حساسیت به زمین‌لغزش است (Rai et al., 2022). یکی از مزیت مدل رگرسیون لجستیک این است که با افزودن یک تابع پیوند مناسب به مدل رگرسیون خطی معمول، متغیرهای مستقل و وابسته می‌توانند به صورت گسسته یا پیوسته باشند. همچنین، در مدل رگرسیون لجستیک، متغیرها لزوماً توزیع نرمال ندارند (Aditian et al., 2018). از سوی دیگر، مدل شبکه‌های عصبی مصنوعی، به دلیل توانایی و عملکرد عالی می‌تواند داده‌های پیچیده و نه چندان دقیق را مورد ارزیابی قرار داده و الگوهای وقوع زمین‌لغزش را استخراج نماید (Yilmaz, 2009). از معایب مدل رگرسیون لجستیک و شبکه‌های عصبی مصنوعی، داشتن فرایندهای ورودی، محاسبه و خروجی پیچیده است، و داده‌ها باید به فرمت ASCII یا فرمت‌های دیگر تبدیل شده است و پس از تکمیل تحلیل‌های آماری، مجدد نیاز به تبدیل به فرمت شبکه‌ای دارند (Lee and Min, 2001).

مدل شبکه‌های عصبی مصنوعی، در مقایسه با روش رگرسیون لجستیک در ارزیابی حساسیت به زمین‌لغزش در حوضه سقزچای، عملکرد محاسباتی مناسب‌تری دارد که با نتایج مطالعات گذشته نیز مطابقت دارد (Lee, 2007; Lee and Pradhan, 2007). در مقایسه با نتایج این پژوهش، می‌توان به ارزیابی حساسیت به زمین‌لغزش با استفاده از روش رگرسیون لجستیک و شبکه‌های عصبی مصنوعی مبتنی بر GIS در منطقه اینژه<sup>۱</sup> کشور کره، اشاره کرد که در آن نیز عملکرد مدل شبکه عصبی

<sup>2</sup> Serchio river valley

<sup>3</sup> Mizunami

<sup>1</sup> Inje

زمین لغزش در مقیاس حوضه، ارزیابی شده است. استفاده از مدل‌های رگرسیون لجستیک و شبکه عصبی مصنوعی، شبیه‌سازی نقشه‌های مختلف حساسیت زمین لغزش را با استفاده از سامانه اطلاعات جغرافیایی امکان پذیر کرد.

نتایج حاصل از مدل شبکه عصبی مصنوعی، دقیق‌ترین بوده و بهتر از مدل رگرسیون لجستیک است. در مدل شبکه‌های عصبی مصنوعی، عوامل تشدیدکننده زمین لغزش‌ها شامل میانگین بارندگی سالانه و بیشینه شتاب افقی زمین، بیشترین تاثیر را بر چگونگی پیش بینی احتمال وقوع زمین لغزش‌ها دارند. بر اساس نتایج این مدل، ۷۱/۴، ۱۴/۳، ۶/۶، ۴/۳ و ۳/۴ درصد از مساحت منطقه به ترتیب در پهنه‌های با حساسیت‌های بسیار کم، کم، متوسط، زیاد و بسیار زیاد قرار گرفته است. به دلیل توانایی و دقت بالای مدل‌های مورد استفاده، رویکرد فعلی را می‌توان برای ارزیابی حساسیت به زمین لغزش در مناطق بسیار بزرگ‌تر نیز اعمال کرد. نتایج ارزیابی حساسیت به زمین لغزش در این پژوهش می‌تواند در تعیین کاربری اراضی، کاهش تخریب و فرسایش خاک، اجرای هرگونه فعالیت توسعه‌ای، جابه‌جایی و توسعه مناطق مسکونی و تعیین ضوابط بهره‌برداری از زمین، به کار برده شود.

### تشکر و قدردانی

نویسندگان این پژوهش مراتب تشکر و قدردانی خود را از پژوهشکده حفاظت خاک و آبخیزداری و مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان اردبیل برای حمایت مالی و معنوی آن‌ها اعلام می‌دارد.

### تعارض منافع

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

نتایج به دست آمده از دو روش فوق، در اکثر مطالعات در دنیا و ایران، حکایت از توانمندی آن‌ها در برآورد دقیق حساسیت احتمالی به زمین لغزش‌ها دارد، اما روش شبکه‌های عصبی مصنوعی با وجود پیچیدگی‌های خاص، دارای دقت بیشتری است. در مدلسازی شبکه‌های عصبی مصنوعی و رگرسیون لجستیک، به ترتیب ۱۴/۳ و ۲۰/۱ درصد از پیکسل‌های زمین لغزشی در پهنه‌های با درجات حساسیت متوسط تا بسیار بالا، قرار گرفته‌اند. پهنه با حساسیت بسیار بالا در روش شبکه‌های عصبی مصنوعی و رگرسیون لجستیک، به ترتیب ۳/۴۴ و ۳/۳۷ درصد از مساحت حوضه را به خود اختصاص داده است و ۸۰/۷ درصد از مساحت این پهنه در مدل شبکه عصبی مصنوعی و ۵۶/۶ درصد در روش رگرسیون لجستیک، درگیر زمین لغزش هستند.

### نتیجه‌گیری

زمین لغزش، یک محدودیت مهم برای توسعه در مناطق لغزش خیز جنوب استان اردبیل به ویژه از طریق فعال شدن مجدد زمین لغزش‌های قدیمی است. کوهستانی بودن منطقه و نیاز به بهره‌برداری‌های مختلف از اراضی در دامنه‌ها، باعث افزایش نیاز به یک مدل تحلیلی دقیق برای تعیین مناطق پر حساسیت شده است. شرایط زمین‌شناسی، توپوگرافی، هیدرولوژی و اقلیمی در حوضه سقزچی در جنوب استان اردبیل، برای وقوع زمین لغزش‌های جدید و یا فعالیت زمین لغزش‌های قدیمی مستعد است و با گسترش فعالیت‌های انسانی نیز تشدید شده است.

احتمال وقوع زمین لغزش در منطقه با استفاده از عوامل درصد شیب، جهات شیب، فاصله از گسل‌ها، فاصله از رودخانه‌ها، فاصله از راه‌ها، فاصله از مناطق مسکونی، واحدهای سنگ‌شناسی، بیشینه شتاب افقی زمین، کاربری اراضی و مجموع بارندگی سالانه، برآورد شد. در این پژوهش، دو مدل تحلیل حساسیت

## منابع مورد استفاده

- Adition, A., Kubota, T., Shinohara, Y., 2018. Comparison of GIS-based landslide susceptibility models using frequency ratio, logistic regression, and artificial neural network in a tertiary region of Ambon, Indonesia. *Geomorphology* 318, 101-111.
- Ajim Ali, S., Parvin, F., Vojteková, J., Costache, R., Thi, N., Linh, T., Pham, Q.B., Vojtek, M., Gigović, L., Ahmad, A., Ghorbani, M.A., 2021. GIS-based landslide susceptibility modeling: a comparison between fuzzy multi-criteria and machine learning algorithms. *Geosci. Front.* 12(2), 857-876.
- Ansari, F., Blurchi, M.C., 1996. Landslides of Ardabile Province, Iran. Geological Survey of Iran, Iran (in Persian).
- Ayalew L., Yamagishi, H., Marui, H., Kanno, T., 2005. Landslides in Sado Island of Japan: Part II. GIS-based susceptibility mapping with comparisons of results from two methods and verifications. *J. Eng. Geol.* 81, 432-445.
- Ayalew, L., Yamagishi, H., 2005. The application of GIS-based logistic regression for landslide susceptibility mapping in the Kakuda-Yahiko Mountains, Central Japan. *Geomorphology* 65, 15-31.
- Barella, C.F., Sobreira, F.G., Zêzere, J.L., 2019. A comparative analysis of statistical landslide susceptibility mapping in the southeast region of Minas Gerais state, Brazil. *Bull. Eng. Geol. Environ.* 78, 3205-3221.
- Bravo-López, E., Fernández Del Castillo, T., Sellers, C., Delgado-García, J., 2022. Landslide susceptibility mapping of landslides with artificial neural networks: multi-approach analysis of backpropagation algorithm applying the neuralnet package in Cuenca, Ecuador. *J. Remote Sens.* 14(3495), 1-30.
- Chen, W.W., Zhang, S., 2021. GIS-based comparative study of Bayes network, Hoeffding tree and logistic model tree for landslide susceptibility modeling. *Catena* 203, 105344.
- Chen, X., Chen, W., 2021. GIS-based landslide susceptibility assessment using optimized hybrid machine learning methods. *Catena* 196, 104833.
- Davis, J.C., Ohlmacher, G.C., 2002. Landslide hazard prediction using generalized logistic regression. Proceedings of 8th Annual Conference of the International Association for Mathematical Geology, Berlin, Germany.
- Demir, G., 2018. Landslide susceptibility mapping by using statistical analysis in the north Anatolian fault zone (NAFZ) on the northern part of Suşehri Town, Turkey. *Nat. Hazards* 92, 133-154.
- Dou, J., Yunus, A.P., Bui, D.T., Merghadi, A., Sahana, M., Zhu, Z., Chen, C.W., Han, Z., Pham, B.T., 2020. Improved landslide assessment using support vector machine with bagging, boosting, and stacking ensemble machine learning framework in a mountainous watershed, Japan. *Landslides* 17, 641-658.
- Falaschi, F., Giacomelli, F., Federici, P.R., Puccinelli, A., D'Amato Avanzi, G., Pochini, A., Ribolini, A., 2009. Logistic regression versus artificial neural networks: landslide susceptibility evaluation in a sample area of the Serchio River valley, Italy. *Nat. Hazards* 50, 551-569.
- Galeandro, A., Doglioni, A., Simeone, V., Šimůnek, J., 2014. Analysis of infiltration processes into fractured and swelling soils as triggering factors of landslides. *Environ. Earth Sci.* 71, 2911-2923.
- Gómez, H., Kavzoglu, T., 2005. Assessment of shallow landslide susceptibility using artificial neural networks in Jabonosa River Basin, Venezuela. *J. Eng. Geol.* 78, 11-27.
- Grozavu, A., Mărgărint, M.C., Patriche, C.V., 2012. Landslide susceptibility assessment in the brăieşti-sineşti sector of iaşi cuesta. *Carpathian J. Earth Environ. Sci.* 5(2), 61-70.
- Hagan, T.M., Demuth, B.H., Beale, H.M., De Jesús, O., 2014. Neural network design, 2nd (ed). Electrical Engineering Series.
- Hashemi Tabatabaei, S., 1998. Landslide hazard zonation in southwest of Ardabil Province in Iran. Ministry of Roads and Urban Development, Tehran, Iran (in Persian).
- Hemmati, R., Dolatimehr, A., Nasirifar, A., Shahbazi, M., Hezhabrpour, Gh., Aghaei, Kh., 2007. Ardabil Province climate. Applied Meteorology Research Center of Ardabil, Islamic Republication of Iran Meteorological Organization, Ministry of Roads and Urban Development, Iran (in Persian).
- Hong, H.Y., Liu, J.Z., Zhu, A.X., 2019. Landslide susceptibility evaluating using artificial intelligence method in the Youfang district (China). *Environ. Earth Sci.* 78(15), 1-20.
- Huang, F.M., Cao, Z.S., Guo, J.F., Jiang, S.H., Li, S., Guo, Z.Z., 2020. Comparisons of heuristic, general statistical and machine learning models for landslide susceptibility prediction and mapping. *Catena* 191, 104580.

- Jianqiang, Z., Yonggang, G., Yong, L., Qiang, Z., Yuhong, J., Huayong, C., Xiaoqing, C., 2022. Zonation-based landslide hazard assessment using artificial neural networks in the China-Pakistan Economic Corridor. *Front. Earth Sci.* 10(927102), 1-15.
- John, R.D., Anne-Gaelle, A., James, D.S., Lavs, B., 2006. Validation of a region-wide model of landslide susceptibility in the Manawatu-Wanganui region of New Zealand. *Geomorphology* 1-4, 70-79.
- Khosravi, M., Jamali, A.A., 2019. forecasting the trend of landslide changes in the northern region of quchan with regard to the factors affecting landslide using neural network, cellular automata-markov, and regression logistics. *J. Geol. and Environ. Hazards* 7(3), 1-17 (in Persian).
- Lee, S., 2007. Comparison of landslide susceptibility maps generated through multiple logistic regression for three test areas in Korea. *Earth Surf. Process. Landf.* 32, 2133-2148.
- Lee, S., Min, K., 2001. Statistical analysis of landslide susceptibility at Yongin, Korea. *Environ. Geol.* 40 (9): 1095-1113.
- Lee, S., Pradhan, B., 2007. Landslide hazard mapping at Selangor, Malaysia using frequency ratio and logistic regression models. *Landslides* 4, 33-41.
- Li, B., Wang, N., Chen, J., 2021. GIS-based landslide susceptibility mapping using information, frequency ratio, and artificial neural network methods in Qinghai Province, northwestern China. *Adv. Civ. Eng. Article ID 4758062: 1-14.*
- Ling, S., Zhao, S., Huang, J., Zhang, X., 2022. Landslide susceptibility assessment using statistical and machine learning techniques: a case study in the upper reaches of the Minjiang River, southwestern China. *Front. Earth Sci.* 10, 986172.
- Liu, Y.L., 2010. Application of logistic regression and artificial neural networks in spatial assessment of landslide hazards. *Hydrogeol. Engin. Geol.* 37(5), 92-96.
- Mathew, J., Jha, V.K., Rawat, G.S., 2009. Landslide susceptibility zonation mapping and its validation in part of garhwal lesser Himalaya, India, using binary logistic regression analysis and receiver operating characteristic curve method. *Landslides* 6, 17-26.
- Meinhardt, M., Fink, M., Tünschel, H., 2015. Landslide susceptibility analysis in central Vietnam based on an incomplete landslide inventory: comparison of a new method to calculate weighting factors by means of bivariate statistics. *Geomorphology* 234, 80-97.
- Menard, S., 2002. *Applied logistic regression analysis*, 2nd (ed.). Sage University Paper Series on Quantitative Applications in Social Sciences, vol. 106, Thousand Oaks, California, USA.
- Meten, M., Bhandary, N.P., Yatabe, R., 2015. GIS-based frequency ratio and logistic regression modelling for landslide susceptibility mapping of Debre Sina area in Central Ethiopia. *J. Mt. Sci.* 12(6), 1355-1372.
- Nhu, V.H., Shirzadi, A., Shahabi, H., Singh, S.K., Al-Ansari, N., Clague, J.J., Jaafari, A., Chen, W.S., Miraki, J., Dou, C., Luu, K., Górski, B., Thai Pham, H., Nguyen, D., Ahmad, B.B., 2020. Shallow landslide susceptibility mapping: a comparison between logistic model tree, logistic regression, naïve bayes tree, artificial neural network, and support vector machine algorithms. *Int. J. Environ. Res. Public Health* 17(8), 1-30.
- Nikandish, N., Mir Sanei, R., 1996. Introduction to Ardabile Province landslides. Iran Ministry of Jihad-e-Agriculture, Tehran, Iran (in Persian).
- Norusis, M.J., 2006. *SPSS 15.0 guide to data analysis*. Pearson Education (US) Publisher, USA.
- Pham, B.T., Bui, D.T., Prakash, I., 2017. Landslide susceptibility assessment using bagging ensemble based alternating decision trees, logistic regression and J48 decision trees methods: a comparative study. *Geotech. Geol. Eng.* 35(6), 2597-2611.
- Polykretis, C., Ferentinou, M., Chalkias, C., 2015. A comparative study of landslide susceptibility mapping using landslide susceptibility index and artificial neural networks in the Krios River and Krathis River catchments (northern Peloponnesus, Greece). *Bull. Eng. Geol. Environ.* 74, 27-45.
- Pourghasemi, H.R., Rahmati, O., 2018. Prediction of the landslide susceptibility: which algorithm, which precision? *Catena* 162, 177-192.
- Rai, D.K., Xiong, D., Zhao, W., Zhao, D., Zhang, B., Mani Dahal, N., Wu, Y., Aslam Baig, M., 2022. An investigation of landslide susceptibility using logistic regression and statistical index methods in Dailekh District, Nepal. *Chinese Geographical Science* 32, 834-851.
- Rana, H., Babu, G.L.S., 2022. Regional back analysis of landslide events using TRIGRS model and rainfall threshold: an approach to estimate landslide hazard for Kodagu, India. *Bull. Eng. Geol. Environ.* 81(4), 160.

- Regmi, A.D., Devkota, K.C., Yoshida, K., Pradhan, B., Pourghasemi, H.R., Kumamoto, T., Akgun, A., 2014. Application of frequency ratio, statistical index, and weights-of-evidence models and their comparison in landslide susceptibility mapping in Central Nepal Himalaya. *Arab. J. Geosci.* 7(2), 725-742.
- Saha, S., Arabameri, A., Saha, A., Blaschke, T., Ngo, P.T.T., Nhu, V.H., Band, S.S., 2021. Prediction of landslide susceptibility in Rudraprayag, India using novel ensemble of conditional probability and boosted regression tree-based on crossvalidation method. *Sci. Total Environ.* 764, 142928.
- Saro, L., Seong, J., Woo, O., Young, K., Moungh-Jin, L., 2016. The spatial prediction of landslide susceptibility applying artificial neural network and logistic regression models: a casestudy of Inje, Korea. *Open Geosci.* 8, 117-132.
- Sdao, F., Lioi, D.S., Pascale, S., Caniani, D., Mancini, I.M., 2013. Landslide susceptibility assessment by using a neuro-fuzzy model: a case study in the Rupestrian heritage rich area of Matera. *Nat. Hazards Earth Syst. Sci.* 13, 395-407.
- Sepah Vand, A.R., Moradi, H.R., Abdolmaleki, P., 2017. Landslide hazard mapping using the artificial neural network a part of Haraz Watershed. *Watershed Manag. Res. (Pajouhesh and Sazandegi)* 29(4)-113, 9-19 (in Persian).
- Shirani, K., Arabameri, A.R., 2015. Landslide hazard zonation using logistic regression method, case study: Dez-e-Oulia Basin. *J. Water Soil Sci.* 19 (72), 321-335 (in Persian).
- Shirani, K., Heydari, F., Arabameri, A., 2017. Comparison of artificial neural network and multivariate regression methods in landslide hazard zonation, case study: Vanak Basin, Isfahan Province. *J. Watershed Engin. Manage.* 9(4), 45-464 (in Persian).
- Shirani, K., Naderi Samani, R., 2022. Determination of effective factors and assessment of landslide susceptibility using random forest and artificial neural network in Doab Samsami region, Chaharmahal va Bakhtiari Province. *Watershed Manage. Res. J.* 35(1), 40-60 (in Persian).
- Su, C., Wang, L., Wang, X., Huang, Z., Zhang, X., 2015. Mapping of rainfall-induced landslide susceptibility in Wencheng, China, using support vector machine. *Nat. Hazards* 76, 1759-1779.
- Talaei, R., 2018. A combined model for landslide susceptibility, hazard and risk assessment. *AUT J. Civil Engin.* 2(1), 11-28.
- Talaei, R., Ghayoumian, J., Shariat Jafari, M., Aliakbarzadeh, E., 2004. Study on effective factor causing landslide in southwest of Khalkhal region. Agriculture Research and Education Organization, Ministry of Jihad-e-Agriculture, Tehran, Iran (in Persian).
- Tanyu, B.F., Abbaspour, A., Alimohammadlou, Y., Tecuci, G., 2021. Landslide susceptibility analyses using Random Forest, C4.5, and C5.0 with balanced and unbalanced datasets. *Catena* 203, 105355.
- Thiery, Y., Maquaire, O., Fressard, M., 2014. Application of expert rules in indirect approaches for landslide susceptibility assessment. *Landslides* 11, 411-424.
- Tian, Y.Y., Xu, C., Chen, J., Zhou, Q., Shen, L.L., 2017. Geometrical characteristics of earthquake-induced landslides and correlations with control factors: a case study of the 2013 Minxian, Gansu, China, Mw 5.9 event. *Landslides* 14, 1915-1927.
- Türköz, M., Tosun, H., 2011. A GIS model for preliminary hazard assessment of swelling clays, a case study in Harran Plain (SE Turkey). *Environ. Earth Sci.* 63(6), 1343-1353.
- Urumeihy, A., MahdaviFar, M.R., 2000. Landslide hazard zonation of the Khorshrostan area, Iran. *Bull. Eng. Geol. Environ.* 58, 207-213.
- Wahono, B.F.D., 2010. Applications of statistical and heuristical methods for landslide susceptibility assessments: a case study in Wadas Lintang sub district, Wonosobo Regency, Central Java Province, Inonesia. MSc Thesis, Gadjah Mada University, International Institute for Geo-Information and Earth Observation.
- Wang, L.J., Guo, M., Sawada, K., Lin, J., Zhang, J., 2016. A comparative study of landslide susceptibility maps using logistic regression, frequency ratio, decision tree, weights of evidence and artificial neural network. *Geosci. J.* 20, 117-136.
- Xie, P., Wen, H., Ma, C., Baise, L.G., Zhang, J., 2018. Application and comparison of logistic regression model and neural network model in earthquake-induced landslides susceptibility mapping at mountainous region, China. *Geomatics Nat. Hazards Risk* 9(1), 501-523.
- Xu, C., Xu, X., Dai, F., Wu, Z., He, H., Shi, F., Wu, X., Xu, S., 2013. Application of an incomplete landslide inventory, logistic regression model and its validation for landslide susceptibility mapping related to the May 12, 2008 Wenchuan earthquake of China. *Nat. Hazards* 68, 883-900.

- Yesilnacar, E., Topal, T., 2005. Landslide susceptibility mapping: a comparison of logistic regression and neural networks methods in a medium scale study, Hendek region (Turkey). *Engin. Geol.* 79(3-4), 251-261.
- Yilmaz, I., 2009. A case study from Koyulhisar (Sivas-Turkey) for landslide susceptibility mapping by artificial neural networks. *Bull. Eng. Geol. Environ.* 68, 297-306.
- Zhang, Y.S., Dong, S.W., Hou, C.T., Guo, C.B., Yao, X., Li, B., Du, J.J., Zhang, J.G., 2013. Geohazards induced by the Lushan Ms7.0 earthquake in Sichuan Province, Southwest China: typical examples, types and distributional characteristics. *Acta Geol. Sin.* 87(3), 646-657.
- Zhang, J., van Westen, C.J., Tanyas, H., Mavrouli, O., Ge, Y., Bajrachary, S., Gurunget, D.R., Dhital, M.R., Khanal, N.R., 2019a. How size and trigger matter: analyzing rainfall- and earthquake-triggered landslide inventories and their causal relation in the koshi river basin, central himalaya. *Nat. Hazards Earth Syst. Sci.* 19(8), 1789-1805.
- Zhang, T., Han, L., Zhang, H., Zhao, Y., Li, X., Zhao, L., 2019b. GIS based landslide susceptibility mapping using hybrid integration approaches of fractal dimension with index of entropy and support vector machine. *J. Mt. Sci.* 16, 1275-1288.
- Zhang, T., Li, Y., Wang, T., Wang, H., Chen, T., Sun, Z., Luo, D., Li, C., Han, L., 2022. Evaluation of different machine learning models and novel deep learning-based algorithm for landslide susceptibility mapping. *Geosci. Lett.* 9(26) 1-16.