



Assessment and Comparative Evaluation of Machine Learning Algorithms (SVM, ANN, and MaxEnt) for Landslide Susceptibility Zonation (LSZ) in the Ziarat Watershed, Golestan Province, Iran

Habib Nazarnejad ^{1*}, Aiding Kornejady ², Chooqhi Bairam Komaki ¹,
Farkhondeh Aghajan Liafu ¹

¹ Department of Watershed Management, Faculty of Range and Watershed Management, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

² Golestan Agricultural and Natural Resources Research and Education Center, Gorgan, Iran

ARTICLE INFO

ABSTRACT

Article History:

Received: 03 March 2026

Revised: 30 May 2026

Accepted: 02 June 2026

Available Online:

04 June 2026

Keywords:

Maximum Entropy
(MaxEnt)

Landslide Susceptibility
Zoning

Artificial Neural Network
(ANN)

Support Vector Machine
(SVM)

Machine Learning

Landslide is one of the most destructive slope hazards in mountainous regions. The performance of three machine learning models — Artificial Neural Network (ANN), Support Vector Machine (SVM), and Maximum Entropy (MaxEnt) — was evaluated and compared for landslide susceptibility mapping in the Ziarat watershed (Golestan Province). A total of 116 landslide points were recorded through GPS field surveys. Stratified random sampling was applied to preserve the spatial distribution of points across geological units, elevation classes, and slope categories. Of these, 81 points (70%) were allocated for training and 35 points (30%) for validation. A total of 5 main factor groups (topography, hydrology, geology, morphometry, and anthropogenic factors) comprising 23 sub-factors were selected: slope, aspect, elevation, valley depth, profile and plan curvature, topographic position index, relative slope position, convergence index, positive and negative openness, rainfall, distance from drainage network, topographic wetness index, stream power index, flow accumulation, geological formation, distance from faults, soil texture, mass balance index, Melton ruggedness index, and vector ruggedness measure. Modeling was performed using ModEco software, and accuracy assessment was carried out using the ROC curve and the Area Under the Curve (AUC) index. Results showed that the ANN model (AUC = 0.936) and the SVM model (AUC = 0.934) performed comparably well, while the MaxEnt model (AUC = 0.904) ranked lower. The most influential factors controlling landslide occurrence were, in order: elevation (corresponding to zones with annual rainfall exceeding 550 mm), the Shemshak and Gorgan Schist formations, and distance from residential areas. Given the ongoing land use changes and increasing construction activity in the Ziarat watershed, restrictions on land use conversion and a ban on construction on steep slopes are recommended.

* Corresponding author: Habib Nazarnejad

E-mail address: h.nazarnejad@gau.ac.ir

How to cite this article: Nazarnejad, H., Kornejady, A., Bairam Komaki, C., & Aghajan Liafu, F. (2026). Assessment and Comparative Evaluation of Machine Learning Algorithms (SVM, ANN, and MaxEnt) for Landslide Susceptibility Zonation (LSZ) in the Ziarat Watershed, Golestan Province, Iran. *Journal of Geography and Environmental Hazards*, ?(?), ?-?. <https://doi.org/10.22067/geoeH.2026.97226.1635>



©2026 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 represent a prevalent and destructive geohazard globally, imposing substantial socioeconomic costs through loss of life, infrastructure damage, and environmental degradation. Their recurrent nature and profound destructive potential underscore the imperative for advanced research in watershed management and geotechnical engineering to devise robust predictive and mitigation strategies. Landslide susceptibility zonation (LSZ) stands as a critical spatial planning and management tool, enabling the precise identification of areas inherently prone to slope instability. This proactive approach facilitates informed land-use planning and targeted risk reduction interventions. The intrinsic complexity and non-linear interactions among diverse geomorphological, hydrological, and anthropogenic factors governing landslide initiation frequently render conventional modeling techniques insufficient. Consequently, the application of sophisticated machine learning algorithms has gained considerable traction in LSZ studies, attributed to their enhanced capacity to model these intricate spatial relationships. Selecting an accurate and computationally efficient model is crucial for reliable landslide prediction and effective risk management in watershed planning. This research endeavors to rigorously assess and comparatively analyze the predictive performance of three prominent machine learning models—Artificial Neural Network (ANN), Support Vector Machine (SVM), and Maximum Entropy (MaxEnt)—in generating accurate landslide susceptibility maps for the Ziarat watershed, located in Golestan Province, Iran. The primary objective is to ascertain the optimal predictive model for this geomorphologically dynamic region, thereby contributing to more effective landslide hazard management.

Material and Methods

The study area, the Ziarat watershed in Golestan Province, Iran, is characterized by diverse topography and geological formations, rendering it susceptible to frequent landslide events. The initial step in landslide susceptibility zoning involves generating a spatial distribution map of historical landslide events, which serves as a critical foundation for subsequent susceptibility and hazard assessment studies. A comprehensive landslide inventory was compiled through detailed field investigations, identifying 116 distinct landslide locations. To ensure model impartiality and robust validation, these locations were stochastically partitioned: 81 points (70%) were designated for model training, while the remaining 35 points (30%) were reserved for independent model validation. A total of 23 conditioning factors, recognized for their influence on landslide occurrence, were meticulously prepared as input variables. These factors encompassed a broad spectrum of environmental parameters, including eleven topographic indices (aspect, slope degree, elevation, valley depth, profile curvature, plan curvature, LS factor, relative slope position (RSP), convergence, positive openness, negative openness), five hydrological variables (rainfall, distance to drainage network, topographic wetness index (TWI), stream power index (SPI), flow accumulation), three geological attributes (Lithology, distance to faults, soil texture), and three morphometric indices (mass balance index (MBI), Melton roughness index (MRI), vector ruggedness measure (VRM)), along with one anthropogenic factor (distance to residential areas). To evaluate multicollinearity among predictive factors, tolerance and Variance Inflation Factor (VIF) indices were computed using SPSS version 26. The machine learning models (ANN, SVM, and MaxEnt) were implemented within the ModEco software environment, configured to elucidate the complex, non-linear relationships between these environmental factors and landslide susceptibility. Model performance was quantitatively evaluated using the Receiver Operating Characteristic (ROC) curve and the Area Under the Curve (AUC) metric.

Results and Discussion

The comparative assessment of the three machine learning models for landslide susceptibility mapping in the Ziarat watershed yielded distinct performance outcomes during the validation phase. The Artificial Neural Network (ANN) model, achieving an Area Under the Curve (AUC) value of 0.936 and the Support Vector Machine (SVM) model with an AUC value of 0.934 exhibited a highly comparable and robust performance. These results signify the exceptional accuracy and reliability of both ANN and SVM models in delineating landslide-prone areas within the study region. In contrast,

the Maximum Entropy (MaxEnt) model, while demonstrating good performance, recorded a comparatively lower AUC of 0.904. The marginal difference in AUC between ANN and SVM suggests their analogous effectiveness in capturing the intricate spatial dependencies between the 23 conditioning factors and landslide incidence. Further analysis focused on quantifying the relative importance of these conditioning factors. This assessment revealed that elevation, geological characteristics, and distance from residential areas were the most influential predictors of landslide susceptibility. This finding is highly consistent with the local geomorphological context, where steep slopes at higher elevations and the presence of unstable geological formations are primary drivers of instability. The significant influence of distance from residential areas highlights the critical role of anthropogenic pressures in exacerbating landslide risk in the watershed.

Conclusion

This research successfully evaluated the efficacy of Artificial Neural Network (ANN), Support Vector Machine (SVM), and Maximum Entropy (MaxEnt) models for landslide susceptibility mapping in the Ziarat watershed. The generated susceptibility maps represent invaluable assets for local authorities and land-use planners, offering a scientific basis for targeted risk management and mitigation strategies. Specifically, these maps can inform the prioritization of slope stabilization measures and guide sustainable development in high-risk zones. This study significantly advances the understanding of landslide susceptibility modeling in complex terrains and offers a transferable methodology for similar investigations in other susceptible regions. For future research, it is recommended to employ hybrid modeling approaches that integrate machine learning algorithms with deep learning architectures to enhance the accuracy and robustness of landslide prediction. Furthermore, given the observed land-use transformations including the expansion of residential zones and increased villa construction in the Ziarat watershed implementing regulatory measures to constrain unplanned land-use changes in this area is strongly advised to mitigate landslide risk.



ارزیابی و مقایسه کارایی مدل‌های یادگیری ماشین SVM، ANN و MaxEnt در تهیه نقشه حساسیت زمین لغزش آبخیز زیارت، استان گلستان

حبیب نظر نژاد^{۱*}، آیدینگ کر نژادی^۲، چوقی بایرام کمکی^۱، فرخنده آقاجان لیافو^۱

^۱ گروه آبخیزداری، دانشکده مرتع و آبخیزداری، دانشگاه علوم کشاورزی و منابع طبیعی، گرگان، ایران

^۲ مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان گلستان، گرگان، ایران

اطلاعات مقاله	چکیده
تاریخچه مقاله: تاریخ دریافت: ۱۴۰۴/۱۲/۱۲ تاریخ بازنگری: ۱۴۰۵/۰۳/۰۹ تاریخ پذیرش: ۱۴۰۵/۰۳/۱۲	زمین لغزش یکی از خسارت‌بارترین مخاطرات دامنه‌ای در مناطق کوهستانی است. کارایی سه مدل یادگیری ماشین شامل شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و بیشینه آنتروپی (MaxEnt) در تهیه نقشه حساسیت زمین لغزش آبخیز زیارت (استان گلستان) ارزیابی و مقایسه شد. با برداشت میدانی GPS، ۱۱۶ نقطه لغزشی ثبت شد. به منظور حفظ پراکنش فضایی نقاط در واحدهای زمین‌شناسی، طبقات ارتفاعی و شیب، از روش نمونه‌گیری تصادفی طبقه‌ای استفاده شد. ۸۱ نقطه (۷۰ درصد) برای آموزش و ۳۵ نقطه (۳۰ درصد) برای اعتبارسنجی تخصیص یافت. در مجموع ۵ گروه عامل اصلی (توپوگرافی، هیدرولوژی، زمین‌شناسی، مورفومتری و انسانی) با ۲۳ زیرعامل (شیب، جهت، ارتفاع، عمق دره، انحنای پروفیل و سطح، شاخص توپوگرافی، موقعیت نسبی شیب، همگرایی، بازشدگی مثبت و منفی، بارندگی، فاصله از آبراهه، شاخص رطوبت توپوگرافی، شاخص توان آبراهه، جریان تجمعی، سازند زمین‌شناسی، فاصله از گسل، بافت خاک، شاخص تعادل جرم، شاخص زبری ملتون، شاخص قدرت بردار) انتخاب شدند. مدل‌سازی با نرم‌افزار ModEco و ارزیابی دقت با منحنی ROC و شاخص سطح زیر منحنی (AUC) انجام شد. یافته‌ها نشان داد که مدل ANN با AUC معادل ۰/۹۳۶ و مدل SVM با AUC معادل ۰/۹۳۴ عملکردی خوب و بسیار نزدیک دارند و مدل MaxEnt با AUC معادل ۰/۹۰۴ در رتبه پایین‌تری قرار می‌گیرد. مؤثرترین عوامل وقوع زمین لغزش به ترتیب ارتفاع (منطبق بر پهنه بارش بالای ۵۵۰ میلی‌متر)، سازندهای شمشک و شیست گرگان، و فاصله از مناطق مسکونی بودند. با توجه به تغییرات کاربری اراضی و افزایش ساخت‌وساز در آبخیز زیارت، اعمال محدودیت در تغییر کاربری و ممنوعیت ساخت‌وساز در دامنه‌های شیب تند پیشنهاد می‌شود.
کلمات کلیدی: بیشینه آنتروپی (MaxEnt) پهنه‌بندی حساسیت زمین لغزش شبکه عصبی مصنوعی (ANN) ماشین بردار پشتیبان (SVM) یادگیری ماشین	

مقدمه


زمین‌لغزش‌ها پدیده‌ای هستند که در اثر برهم‌کنش عوامل اقلیمی، هیدرولوژیکی، زمین‌شناختی، ژئومورفولوژیکی و انسانی رخ می‌دهند (Petley, 2012; Kirschbaum, Stanley & Zhou, 2015; Froude & Petley, 2018). این ماهیت چندعاملی سبب شده است که زمین‌لغزش‌ها سالانه تلفات جانی و خسارات زیست‌محیطی گسترده‌ای در مناطق کوهستانی جهان به‌جای بگذارند (Petley, 2012; Dastranj, Karimi Sangchini & Noor, 2024). با افزایش فشار جمعیتی و تغییرات کاربری اراضی گسترش این پدیده در مناطق روستایی (Guns & Vanacker, 2014; Maki Mateso et al., 2023) و شهری (Gariano & Guzzetti, 2016; Ozturk et al., 2022) تشدید شده است. زمین‌لغزش‌ها به‌دلیل تلفات جانی و تهدید امنیت عمومی، نیازمند تحلیل حساسیت‌پذیری دقیق هستند (Yeon, Han, & Ryu, 2010; Lee, 2005; Mao et al., 2024; Sadati, Mousavi, Vahabzadeh Kebria, & Roshun, 2025). ایران به دلیل توپوگرافی کوهستانی، فعالیت زمین‌ساختی، لرزه‌خیزی، تنوع اقلیمی، رشد جمعیت و مداخلات انسانی، همراه با کاستی‌های مدیریتی، در زمره بلاخیزترین کشورهای آسیایی و جهانی قرار دارد (Dastranj et al., 2024). هدف اصلی پهنه‌بندی حساسیت زمین‌لغزش، پیش‌بینی توزیع فضایی و احتمال رخداد آن است (Wang et al., 2020). پهنه‌بندی حساسیت زمین‌لغزش (LSZ¹) به‌عنوان راهبرد پیشگیرانه، امکان شناسایی مناطق پرخطر و اتخاذ تدابیر مدیریتی (مانند پایدارسازی شیب و پیشگیری از ساخت‌وسازهای نامناسب) را فراهم می‌آورد (Nanehkaran, Mao, Azarafza, Kockar, & Zhu, 2021; Nikoobakht, Azarafza, 2021; Akgun & Derakhshani, 2022; Ado et al., 2022; Iadanza, Esposito & Scarascia-Mugnozza, 2015; Arabameri, Rezaei, Yamani & Shirani, 2020; Ghiasi, Rajabzadeh, Kornejady & Pourghasemi, 2019; Najirad, Feiznia & Nazari Samani, 2017). روش‌های مبتنی بر هوش مصنوعی (Dastranj & Karimi Sangchini, 2022; Nanehkaran et al., 2023) می‌توانند حجم عظیمی از داده‌ها را مدیریت کرده و روابط پیچیده غیرخطی عوامل محیطی را کشف کنند (Pyakurel, Dahal & Gautam, 2023; Santangelo, Forte, De Falco, Chirico & Santo, 2021; Forte et al., 2021). مدل‌های یادگیری ماشین (ML²) به‌دلیل ماهیت مبتنی بر داده و تکرارپذیری، در تشخیص الگوهای وقوع پدیده زمین‌لغزش کارایی بالایی نشان می‌دهند (Gilanipoor, Motevalli & Derafshi, 2025). کارایی نسبی این مدل‌ها نسبت به دیگر روش‌ها در مطالعات متعدد اثبات شده است (Trigila et al., 2015). انتخاب مدل دقیق و کارآمد، نقش حیاتی در پیش‌بینی و مدیریت زمین‌لغزش برای برنامه آمایش سرزمین آبخیز ایفا می‌کند. مدل‌هایی مانند شبکه عصبی مصنوعی (Moavi, 2022; Yao et al., 2019; Harmouzi et al., 2019; Elmizadeh & Entezari, 2025)؛ رگرسیون لجستیک (Hemasinghe, Rangali, Deshapriya & Samarakoon, 2018)، ماشین بردار پشتیبان (Hong, Pradhan, Xu & Bui, 2015) و جنگل تصادفی (Sun, Xu, Wen & Wang, 2021) به‌دلیل دقت بالا در پردازش اطلاعات، برای تولید نقشه‌های حساسیت زمین‌لغزش استفاده شده‌اند. در ایران و بسیاری از مناطق دیگر جهان، پژوهش‌های متعددی در زمینه پهنه‌بندی حساسیت وقوع زمین‌لغزش با بهره‌گیری از روش‌ها و رویکردهای گوناگون انجام شده است. به عنوان مثال، سپهوند و بیرانوند (Sepahvand & Beiranvand, 2024) در بخشی از آبخیز هراز با استفاده از الگوریتم‌های ماشین بردار پشتیبان (SVM³)، فرآیند گاوسی (GPR) و جنگل تصادفی (RF⁴) به ارزیابی پهنه‌بندی حساسیت وقوع زمین‌لغزش پرداختند. نتایج نشان داد که مدل RF با مقدار $AUC^5 = 0.99$ و $Accuracy = 0.99$ بهترین عملکرد را داشته و جهت شیب حساس‌ترین عامل در وقوع زمین‌لغزش شناخته شد. دسترنج و کریمی سنگچینی (Dastranj & Karimi Sangchini, 2022) با

1- Landslide Susceptibility Zonation
2- Machine Learning
3- Support Vector Machine
4- Radom Forest
5- Area Under the Curve

به کارگیری مدل حداکثر آنتروپی (MaxEnt) به پهنه‌بندی حساسیت وقوع زمین‌لغزش در حوزه آبخیز بار نیشابور در استان خراسان رضوی پرداختند. نتایج نمودار Jackknife نشان داد طول شیب، جهت شیب بیشترین تأثیر را در بروز زمین‌لغزش دارند. ارزیابی مدل با شاخص سطح زیر منحنی دقت بسیار خوبی را در مرحله آموزش ($AUC=0.92$) و اعتبارسنجی ($AUC=0.87$) نشان داد. نانهکران و همکاران (Nanehkaran et al., 2023) در ارزیابی حساسیت زمین‌لغزش نشان دادند که مدل‌های مبتنی بر هوش مصنوعی، به ویژه شبکه‌های عصبی مصنوعی (ANN^1)، به دلیل ارائه نتایج دقیق‌تر، بر روش‌های کمی و کیفی سنتی برتری دارند. سارو و همکاران (Saro, Woo, Kwan-Young & Moung-Jin, 2016) در کره جنوبی، با به کارگیری GIS، حساسیت زمین‌لغزش را با مقایسه مدل‌های شبکه عصبی مصنوعی (ANN) و رگرسیون لجستیک پهنه‌بندی کردند. مدل ANN عملکرد بهتری از رگرسیون لجستیک نشان داد. در آبخیز کاکاشرف استان لرستان فتحی‌گنجی و همکاران (Fathiganji, Nazari Samani, Feiznia & Nourizdan, 2024) به بررسی حساسیت زمین‌لغزش با استفاده از روش‌های یادگیری ماشین پرداختند. با به کارگیری الگوریتم جنگل تصادفی (RF)، از میان ده متغیر محیطی، فاصله از گسل و شیب به عنوان مهم‌ترین عوامل مؤثر بر حساسیت زمین‌لغزش شناسایی شدند. برای پیش‌بینی مناطق مستعد زمین‌لغزش، مدل‌های شبکه عصبی مصنوعی (ANN) و MaxEnt مقایسه شدند. مدل ANN با سطح زیر منحنی 0.92 برتری قابل توجهی نسبت به MaxEnt با سطح زیر منحنی 0.80 نشان داد. در راستای ارزیابی کارایی دو مدل ماشین بردار پشتیبان (SVM) و درخت رگرسیون تقویت شده (BRT) در مدل‌سازی مکانی، کرنژادی و پورقاسمی (Kornejady & Poorghasemi, 2019) به پهنه‌بندی حساسیت زمین‌لغزش در آبخیز چهل‌چای پرداختند. تحلیل نتایج نشان داد که مدل SVM از نظر آماری، عملکرد بهتری در تعیین مناطق مستعد زمین‌لغزش داشته و مساحت زیر منحنی (AUC) آن به 0.82 رسید؛ در حالی که مدل BRT با $AUC=0.77$ در جایگاه بعدی قرار گرفت. نتایج تحقیقات پیشین نشان داده‌اند که الگوریتم‌های یادگیری ماشین، با فراهم آوردن سرعت تحلیل و دقت بالاتر در تهیه نقشه‌های خطر، به عنوان ابزاری ضروری برای ارزیابی ریسک‌های زمین‌لغزش مطرح شده‌اند. این ضرورت در آبخیز زیارت استان گلستان به‌طور ویژه احساس می‌شود زیرا این آبخیز نقش مهمی در تأمین حدود ۳۰ درصد از آب شرب شهر گرگان ایفا می‌کند. ویژگی‌های زمین‌شناسی غالب منطقه، شامل گسترش سازندهای فرسایش‌پذیر شمشک (متشکل از تناوب شیل، ماسه‌سنگ و لایه‌های زغال‌سنگ با درزه و شکاف‌های فراوان) و شیب‌های گرگان (متشکل از شیب‌های میکادار و کلریتی با برگواگی شدید و هوازدگی بالا) که پوشش غالب آبخیز را تشکیل می‌دهند، آسیب‌پذیری بوم‌سازگان را در برابر حرکات دامنه‌ای افزایش داده است. این شرایط، همراه با تغییرات کاربری اراضی، فرآیند تولید رسوب را تشدید نموده و کیفیت منابع آب و خاک را به مخاطره انداخته است. وقوع زمین‌لغزش‌های سالانه در این آبخیز خسارات قابل توجهی بر زیرساخت‌ها و جوامع محلی تحمیل می‌کند. بر اساس مطالعات پیشین در آبخیز زیارت، حدود $13/62$ درصد از مساحت آبخیز در پهنه خطر زیاد و $9/04$ درصد در پهنه خسارت زیاد تا خیلی زیاد قرار دارد که شامل روستای زیارت و تأسیسات مرتبط با آن می‌شود (Kornejady, 2013). افزون بر این، در باردید میدانی مشاهده شد زمین‌لغزش‌های منطقه موجب خسارت به جاده دسترسی، خطوط انتقال آب شرب شهر گرگان و تخریب باغات روستاییان شده است. برای نهادهای اجرایی و برنامه‌ریزان، توسعه برنامه‌های مدیریت بحران و انجام ارزیابی کمی مناطق مستعد زمین‌لغزش برای کاهش خطرات آتی از اهمیت بالایی برخوردار است. در همین راستا، پژوهش حاضر به پهنه‌بندی حساسیت زمین‌لغزش در آبخیز زیارت متمرکز بوده و عملکرد سه روش پیشرفته یادگیری ماشین، شامل شبکه عصبی مصنوعی (ANN)، مدل بیشینه آنتروپی (MaxEnt) و ماشین بردار پشتیبان (SVM) را مورد ارزیابی و مقایسه قرار می‌دهد.

منطقه مورد مطالعه

حوزه آبخیز زیارت با وسعت ۹۱۱۰ هکتار در جنوب شهرستان گرگان واقع شده و یکی از زیرحوزه‌های قره‌سو است. مختصات جغرافیایی آن ۱° ۳۷' ۳۶" تا ۵۵' ۴۵" ۳۶° عرض شمالی و ۴۷' ۲۳" ۵۴° تا ۱۱' ۳۱" ۵۴° طول شرقی است (شکل ۱). میانگین بارندگی سالانه آبخیز برابر ۵۵۰ میلی‌متر و متوسط دمای سالانه ۱۰ درجه سانتی‌گراد است. ارتفاع حداکثر و حداقل به ترتیب ۳۰۲۷ و ۵۵۸ متر از سطح دریا است. شیب متوسط آن ۴۸/۱۸ درصد است که نقش مهمی در رسوب‌دهی، فرسایش و حرکات توده‌ای دارد. از نظر سنگ‌شناسی، سازندهای سنگی منطقه شامل سازند خوش‌یلاق، لار، مبارک، شمشک و شیست گرگان سازند شمشک (متشکل از تناوب شیل، ماسه‌سنگ و لایه‌های زغال‌سنگ با درزه و شکاف‌های فراوان) و سازند شیست گرگان (متشکل از سنگ‌های دگرگونی نظیر کلریت، سرسیت، آمفیبول و شیست با برگراری شدید و هوازدگی بالا) به ترتیب بیشترین نقش را در وقوع زمین‌لغزش دارند. این دو سازند فرسایش‌پذیر بخش زیادی از سطح آبخیز را پوشش می‌دهند. کاربری‌های غالب منطقه شامل جنگل، مرتع، اراضی کشاورزی، باغات، دیمزارهای رها شده و مناطق مسکونی است. بر اساس نتایج پژوهش‌های انجام‌شده قبلی در حوزه آبخیز زیارت، بیشترین میزان وقوع زمین‌لغزش در کاربری‌های جنگل و اراضی کشاورزی می‌باشد (Saberchenari, Salmani & Mirabedini, 2018). این امر می‌تواند ناشی از تغییرات کاربری اراضی (از جمله جنگل‌زدایی و تبدیل اراضی جنگلی به دیمزارهای رها شده) و نیز ساخت‌وسازهای غیراصولی در شیب‌های تند باشد که فشار انسانی را بر دامنه‌های ناپایدار افزایش داده است (Kornejady, 2013).



شکل ۱- موقعیت جغرافیایی آبخیز زیارت گرگان، استان گلستان، ایران

Fig. 1. Geographic Location of the Ziarat Watershed, Gorgan, Golestan Province, Iran

مواد و روش‌ها

پژوهش حاضر با هدف تهیه نقشه حساسیت زمین لغزش به منظور کاربرد در برنامه‌ریزی مدیریت خطر و آمایش سرزمین طراحی شده است. از نظر ماهیت و روش اجرا، این پژوهش در زمره پژوهش‌های توصیفی-تحلیلی و مبتنی بر مدل‌سازی داده‌کاوی قرار دارد. از سه الگوریتم یادگیری ماشین شامل شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و بیشینه آنتروپی (MaxEnt) برای مدل‌سازی روابط غیرخطی بین عوامل محیطی و وقوع زمین لغزش استفاده شده است. انتخاب این روش‌ها مبتنی بر مرور پیشینه پژوهش و موفقیت اثبات‌شده آن‌ها در پهنه‌بندی مخاطرات دامنه‌ای در مناطق کوهستانی بوده است (Pourghasemi, Pradhan, 2024). نخستین مرحله در پهنه‌بندی حساسیت زمین لغزش، تهیه نقشه پراکنش زمین لغزش‌های پیشین است که پیش‌نیاز کلیدی مطالعات پهنه‌بندی محسوب می‌شود. داده‌ها از طریق بازدیدهای میدانی، مطالعات کتابخانه‌ای و مراجعه به اداره کل منابع طبیعی و آبخیزداری و شرکت آب منطقه‌ای استان گلستان جمع‌آوری شدند. برای ثبت نقاط لغزشی، از دستگاه موقعیت‌یاب جغرافیایی (GPS) استفاده شد. نرم‌افزار Google Earth برای ثبت اولیه موقعیت نقاط صعب‌العبور به کار رفت و نقاط ثبت‌شده از این طریق، در بازدیدهای میدانی با GPS کنترل و تأیید میدانی شدند. در مجموع ۱۱۶ نقطه لغزشی شناسایی و ثبت شد. از این تعداد، ۸۱ نقطه (۷۰ درصد) به روش تصادفی طبقه‌ای بر اساس واحدهای زمین‌شناسی، طبقات ارتفاعی و طبقات شیب برای آموزش مدل‌ها و ۳۵ نقطه (۳۰ درصد) برای اعتبارسنجی مستقل تخصیص یافتند.


انتخاب عوامل مؤثر بر زمین لغزش


در این پژوهش، ۲۳ عامل در قالب ۵ گروه اصلی شامل توپوگرافی (۱۱ عامل)، هیدرولوژی (۵ عامل)، زمین‌شناسی (۳ عامل)، مورفومتری (۳ عامل) و انسانی (۱ عامل) انتخاب شدند. مبنای انتخاب این عوامل مرور مطالعات قبلی (Pourghasemi et al., 2012; Trigila et al., 2015; Ado et al., 2022) و قابلیت دسترسی داده با توان تفکیک مکانی ۱۲/۵ متر و اثبات همبستگی معنادار با زمین لغزش در مطالعات پیشین منطقه و استان گلستان بود (Kornejady, Ownegh, Pourghasemi, Bahremand & Motamedi, 2020; Pourghasemi et al., 2012).


تهیه لایه‌های اطلاعاتی و نرم‌افزارهای مورد استفاده

نقشه مدل رقومی ارتفاع (DEM) با قدرت تفکیک (۱۲/۵ × ۱۲/۵) متر از سایت دانشگاه آلاسکا (ASF Data Search, alaska.edu) تهیه شد. از DEM و نقشه توپوگرافی ۱:۵۰۰۰۰ برای استخراج لایه‌های فاصله از آبراهه، درجه شیب و جهت شیب در نرم‌افزار ArcGIS 10.8 استفاده شد. نقشه زمین‌شناسی ۱:۱۰۰۰۰۰ سازمان زمین‌شناسی کشور برای تهیه لایه‌های سنگ‌شناسی و فاصله از گسل به کار رفت. سایر لایه‌ها (شامل انحنای پروفیل و سطح، شاخص رطوبت توپوگرافی، شاخص توان آبراهه، شاخص تعادل جرم، شاخص زبری ملتون، شاخص قدرت بردار، شاخص‌های بازشدگی مثبت و منفی، همگرایی و جریان تجمعی) با استفاده از نرم‌افزار SAGA GIS و بر اساس الگوریتم‌های استاندارد زونبرگن و ثورن (Zevenbergen & Thorne, 1987) برای انحنای و بون و کرکبی (Beven & Kirkby, 1979) برای TWI تهیه شدند.

نظرنژاد و همکاران ارزیابی و مقایسه کارایی مدل‌های یادگیری ...







شکل ۲- عوامل مؤثر بر وقوع زمین لغزش در آبخیز زیارت
Fig. 2. Factors influencing landslide occurrence in Ziarat Watershed

بررسی هم‌خطی عوامل

وجود هم‌خطی بین عوامل باعث کاهش دقت نقشه حساسیت زمین لغزش می‌شود (Arabameri et al., 2020). برای بررسی هم‌خطی عوامل از شاخص‌های Tolerance و VIF در محیط SPSS26 استفاده شد. مقدار Tolerance کمتر از ۰/۱ و مقدار VIF بزرگ‌تر از ۱۰ نشان‌دهنده هم‌خطی بین عوامل است (Ghiasi, Rajabzadeh, Najirad, 2017; Feiznia & Nazari Samani, 2017).

مدل‌های یادگیری ماشین

در این پژوهش از سه مدل شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و بیشینه آنتروپی (MaxEnt) برای پهنه بندی زمین لغزش استفاده شد. مطالعات متعددی کارایی بالای این مدل‌ها را در شناسایی الگوهای پیچیده فضایی ناشی از تعامل غیرخطی عوامل محیطی تأیید کرده‌اند. مدل‌های شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و بیشینه

آنتروپی (MaxEnt) از روش‌های قدرتمند یادگیری ماشین برای پیش‌بینی مناطق حساس به زمین‌لغزش هستند (Kornejady & Pourghasemi, 2019).

شبکه عصبی مصنوعی یک روش لایه‌ای است که از نرون‌های به هم پیوسته (شامل لایه‌های ورودی، پنهان و خروجی) تشکیل شده و توانایی بالایی در یادگیری الگوهای پیچیده و تعاملات غیرخطی و خطی میان متغیرها دارد (Nanehkaran et al., 2023). مهم‌ترین فرایند یادگیری در این شبکه، الگوریتم پس‌انتشار خطا است که با مقایسه خروجی شبکه با نتیجه مطلوب، وزن اتصال شبکه‌ها را به‌طور مکرر بهینه‌سازی کرده تا نرخ خطای قابل قبولی به دست آید (Pham, Pradhan, Bui, Prakash & Dholakia, 2016).

مدل بیشینه آنتروپی (MaxEnt) بر اساس اصل حداکثر بی‌نظمی در علم اطلاعات عمل می‌کند و به دنبال تعیین شبکه ارتباطات بین متغیرهای وابسته و مستقل است (Dastranj & Karimi Sangchini, 2024). این مدل با استخراج توزیع‌های احتمالاتی (نظیر توزیع Gibbs از داده‌ها)، نقش و وزن تأثیر هر متغیر را تعیین می‌کند.

مدل ماشین بردار پشتیبان (SVM) یک روش یادگیری نظارت‌شده مبتنی بر نظریه یادگیری آماری (SLT) برای طبقه‌بندی و رگرسیون است. ایده اصلی SVM یافتن ابرصفحه جداکننده بهینه است که فاصله حاشیه‌ای بین بردارهای پشتیبان (نقاط آموزشی نزدیک به صفحه) متعلق به دو کلاس (حضور و عدم حضور لغزش) را به حداکثر برساند. برای دسته‌بندی داده‌های غیرخطی با پیچیدگی بالا، داده‌ها با استفاده از توابع هسته (مانند توابع پایه شعاعی (RBF)، چندجمله‌ای یا سیگموئید) به فضای با ابعاد بالاتر منتقل می‌شوند تا جداسازی خطی امکان‌پذیر شود. هسته RBF اغلب به دلیل نتایج پیش‌بینی بهتر در مسائل غیرخطی، به عنوان هسته پیش‌فرض برای تهیه نقشه حساسیت زمین‌لغزش مورد استفاده قرار می‌گیرد (Kalantar et al., 2020).

اعتبارسنجی مدل

پس از تهیه نقشه حساسیت زمین‌لغزش، ارزیابی با داده‌های اعتبارسنجی در نرم‌افزارهای اکسل (Excel)، سیستم موقعیت جغرافیایی (GIS) و ModEco انجام شد. دقت مدل‌ها با منحنی تشخیص عملکرد نسبی (ROC^1) سنجیده شد. منحنی ROC نموداری است که در آن نسبت پیکسل‌هایی که به اشتباه توسط مدل به عنوان زمین‌لغزش شناسایی شده‌اند و در واقعیت فاقد زمین‌لغزش بوده‌اند روی محور افقی (مثبت غلط یا Specificity) و در برابر مقدار مکمل آن یعنی نسبت پیکسل‌هایی که به درستی توسط مدل تحت عنوان دارای زمین‌لغزش شناسایی شده‌اند (مثبت درست یا Sensitivity) روی محور عمودی ترسیم می‌شود. مساحت زیر این منحنی AUC نام داشته و مقدار آن بین ۰/۵ تا ۱ متغیر است. AUC برابر با ۰/۵ معادل مدل خنثی (نتایج ناشی از شانس) بوده و هرچه این مقدار به یک نزدیک‌تر شود کارایی مدل افزایش می‌یابد (Pontius & Schneider, 2001; Park & Kim, 2019).

نتایج و بحث

نتایج بررسی هم‌خطی بین عوامل مؤثر بر زمین‌لغزش

بررسی هم‌خطی عوامل از شاخص‌های Tolerance و VIF در نرم‌افزار SPSS26 انجام شد. VIF برای DEM برابر ۶/۰۶۶ (بالاترین) و برای جهت شیب ۱/۲۱۱ (پایین‌ترین) بود. با توجه به آستانه پذیرفته شده (VIF بزرگ‌تر از ۱۰) هیچ عاملی حذف نشد و همه عوامل حفظ شدند. مقادیر تمام عوامل و آماره‌ها در جدول ۱ ارائه شده است.


جدول ۱- مقادیر عوامل و آماره‌ها برای بررسی هم‌خطی عوامل

Table 1 - Values of factors and statistics for examining multicollinearity of factors

عوامل Factors	آماره‌های هم خطی Collinearity Statistics		عوامل Factors	آماره‌های هم خطی Collinearity Statistics	
	Tolerance	VIF		Tolerance	VIF
جهت Aspect	0.826	1.211	بارندگی Rainfall	0.448	2.233
همگرایی Convergence	0.199	5.036	فاصله از جاده Resid Distance	0.293	3.409
مدل رقومی ارتفاع DEM	0.165	6.066	موقعیت نسبی شیب RSP	0.227	4.403
فاصله از گسل Fault Distance	0.583	1.716	درجه شیب Slope Degree	0.154	6.479
جریان تجمعی Flow Accumulation	0.627	1.594	بافت خاک Soil Texture	0.534	1.872
زمین شناسی Geology	0.749	1.335	شاخص توان آبراهه SPI	.862	1.160
شاخص توپوگرافی LSFactor	0.312	3.201	فاصله از آبراهه Stream Distance	0.620	1.613
شاخص تعادل جرم MBI	0.605	1.652	شاخص رطوبت توپوگرافی TWI	0.125	8.004
شاخص زبری ملتون MRI	0.598	1.672	عمق دره Valley_depth	0.173	5.781
بازشدگی منفی Neg_Openness	0.214	4.667	شاخص قدرت بردار VRM	0.692	1.445
شاخص انحنای سطح Plan_C	0.338	2.959	بازشدگی مثبت Pos_Openness	0.165	6.053
شاخص انحنای پروفیل Profile C	0.413	2.421			

نقشه حساسیت زمین لغزش

نقشه حساسیت زمین لغزش با مدل‌های مورد استفاده در شکل ۳ ارائه شده است.



شکل ۳- نقشه حساسیت زمین لغزش آبخیز زیارت با مدل‌های شبکه عصبی مصنوعی، بیشینه آنتروپی و ماشین بردار پشتیبان

Fig. 3. Landslide Susceptibility Map of the Ziarat Watershed Derived from Artificial Neural Network (ANN), Maximum Entropy (ME), and Support Vector Machine (SVM) Models

جدول ۲- مساحت و درصد کلاس‌های حساسیت زمین‌لغزش در آبخیز زیارت

Table 2- Area and Percentage Distribution of Landslide Susceptibility Classes in the Ziarat Watershed

مدل Model	درصد نقاط زمین‌لغزش واقعی در هر کلاس Percentage of Actual Landslide Points per Class	مساحت (هکتار) Area(ha)	کلاس‌های حساسیت زمین‌لغزش Landslide Susceptibility Classes
شبکه عصبی مصنوعی Artificial Neural Network	55	5097.34	خیلی کم (Very Low)
	7	569.6	کم (Low)
	6	522.18	متوسط (Medium)
	8	722.31	زیاد (High)
	24	2204.34	خیلی زیاد (Very High)
بیشینه آنتروپی Maximum Entropy	40	3672.81	خیلی کم (Very Low)
	17	1548.66	کم (Low)
	13	1166.26	متوسط (Medium)
	13	1190.83	زیاد (High)
	17	1533.01	خیلی زیاد (Very High)
ماشین بردار پشتیبان Support Vector Machine	40	3637.23	خیلی کم (Very Low)
	16	1456.46	کم (Low)
	14	1263.35	متوسط (Medium)
	14	1297.28	زیاد (High)
	16	1456.45	خیلی زیاد (Very High)

نقشه حساسیت زمین‌لغزش آبخیز زیارت با سه مدل (ANN, SVM, ME) به پنج کلاس خیلی کم تا خیلی زیاد طبقه‌بندی شد (شکل ۳). در مدل ماشین بردار پشتیبان و بیشینه آنتروپی حدود ۳۰ درصد و در مدل شبکه عصبی مصنوعی حدود ۳۲ درصد از آبخیز زیارت در محدوده خطر زیاد تا بسیار زیاد نسبت به رخداد زمین‌لغزش قرار گرفته است (جدول ۲). براساس نتایج حاصل از منحنی ROC، مقدار سطح زیر منحنی (AUC) برای مدل بیشینه آنتروپی در مرحله اعتبارسنجی و آموزش به ترتیب ۰/۹۰۴ و ۰/۹۲۷؛ برای مدل ماشین بردار پشتیبان به ترتیب برابر ۰/۹۳۴ و ۰/۹۴۳ و مدل شبکه عصبی مصنوعی به ترتیب برابر ۰/۹۳۶ و ۰/۹۳۹ می‌باشد (جدول ۳). نتایج، نشان‌دهنده عملکرد قابل قبول این مدل‌ها در پهنه‌بندی حساسیت زمین‌لغزش‌ها در آبخیز زیارت است.

جدول ۳- میزان دقت مدل‌ها برای زمین‌لغزش‌های آبخیز زیارت

Table 3- Model Accuracy Metrics for Landslides in the Ziarat Watershed

مدل Model	شبکه عصبی مصنوعی ANN		ماشین بردار پشتیبان SVM		بیشینه آنتروپی MaxEnt	
دقت مدل Model Accuracy	آموزش Training	اعتبارسنجی Validation	آموزش Training	اعتبارسنجی Validation	آموزش Training	اعتبارسنجی Validation
	0.939	0.936	0.943	0.934	0.927	0.904


به منظور ارزیابی کارایی مدل‌ها، از منحنی ROC و نسبت ۷۰ درصد داده‌های آموزشی در مقابل ۳۰ درصد داده‌های اعتبارسنجی استفاده شد. این رویکرد با نتایج و روش‌های مطالعات پیشین بابابی و همکاران (Babbarabi, Lorestani & Esmaili, 2025)؛ ژائو و همکاران (Zhao, Liu & Xu, 2021)؛ کرمی و همکاران (Karami, Bayati Khatibi, Kheirizadeh & Mokhtari Asl, 2019) هم‌جهت بوده و هماهنگی دارد. ارزیابی عملکرد مدل‌ها با استفاده از شاخص سطح زیر منحنی (AUC)، نشان داد که مدل ماشین بردار پشتیبان (SVM) و مدل شبکه عصبی مصنوعی عملکرد نزدیکی داشتند و هر دو دارای دقت خیلی خوبی بودند. ولی SVM با دقت آموزشی کمی بالاتر و مقاومت به بیش پردازش (تفاوت کمتر بین AUC آموزش و اعتبارسنجی)، گزینه مطلوب‌تری برای این

مطالعه محسوب می‌شود. نتایج این تحقیق با مطالعات کرنژادی و پورقاسمی (Kornejady & Pourghasemi, 2019)، سویارتو و همکاران (Suyarto et al., 2023)، فام و همکاران (Pham, Pradhan, Bui, Prakash & Dholakia, 2016)، فونگ و همکاران (Phong et al., 2021)، حمیدی و همکاران (Hamidi et al., 2023)، قنواتی و همکاران (Ghanavati, Ahmadabadi, & Gholami, 2019)، حنیفی‌نیا و نظرنژاد (Hanifinia & Nazarnejad, 2022)، سلامت و همکاران (Selamat, Abd Majid & Mohd Taib, 2023)، نانهکران و همکاران (Nanehkaran et al., 2023)، بهمنی و همکاران (Bahmani, Zangneh Tabar, Mohammadi & Matai, 2021) مبنی بر کارایی خوب مدل شبکه عصبی مصنوعی همسو است.

بررسی‌ها نشان داد از آنجا که روابط میان متغیرهای مؤثر در وقوع زمین‌لغزش معمولاً غیرخطی، پیچیده و چندبعدی هستند، استفاده از روش‌های یادگیری ماشین مانند شبکه‌های عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM)، رویکردی مؤثر برای مدل‌سازی دقیق این روابط و پیش‌بینی‌پذیری بالاتر پدیده محسوب می‌شود. این مدل‌ها برخلاف روش‌های آماری کلاسیک، نیازمند فرض توزیع خاصی از داده‌ها نبوده و بر پایه یادگیری الگوهای غیرخطی و استخراج روابط پنهان میان متغیرها عمل می‌کنند. به بیان دیگر، با توجه به تولدایی این مدل‌ها در شناسایی ارتباطات پیچیده میان عوامل زمین‌لغزش، کاربرد آن‌ها در پهنه‌بندی حساسیت لغزش‌ها منجر به افزایش دقت، پایداری و قابلیت اعتماد نتایج نسبت به روش‌های آماری متداول می‌شود.

ارزیابی کمی عملکرد مدل‌ها در حوزه آبخیز زیارت نشان داد که مدل SVM با AUC اعتبارسنجی ۰/۹۳۴ و AUC آموزش ۰/۹۴۳، کمترین اختلاف بین مرحله آموزش و اعتبارسنجی (۰/۰۰۹) را در میان سه مدل به خود اختصاص می‌دهد که حاکی از مقاومت بالای این مدل به بیش‌برازش (overfitting) بر داده‌های آموزشی در این آبخیز است. در مقایسه، مدل ANN با اختلاف ۰/۰۰۳ (AUC اعتبارسنجی ۰/۹۳۶ و آموزش ۰/۹۳۹) و مدل MaxEnt با اختلاف ۰/۰۲۳ (AUC اعتبارسنجی ۰/۹۰۴ و آموزش ۰/۹۲۷) قرار دارند. این یافته‌های کمی نشان می‌دهد که در شرایط جغرافیایی و محیطی آبخیز زیارت، مدل SVM به دلیل پایه‌های نظری قوی، الگوریتم غیرخطی کارآمد، دقت بالا در فرآیند بهینه‌سازی و تنظیم پارامترها، و قابلیت ذاتی در جلوگیری از بیش‌برازش بر داده‌های آموزشی عملکرد بهتری داشته است. افزون بر این، بخشی از برتری این مدل در منطقه مورد مطالعه را می‌توان به تناسب ساختار داده‌های این حوزه (با ۲۳ عامل محیطی و ۱۱۶ نقطه لغزشی) با فرضیات مدل‌های رگرسیونی و نیز دقت بالای تهیه و مدل‌سازی لایه‌های اطلاعاتی نسبت داد. به‌طور کلی، در سال‌های اخیر مدل SVM به دلیل توان بالای طبقه‌بندی، قدرت تعمیم مناسب و قابلیت غلبه بر محدودیت‌های روش‌های آماری کلاسیک، به یکی از کارآمدترین ابزارهای یادگیری ماشین در تحلیل و پیش‌بینی پدیده‌های زمین‌لغزش تبدیل شده است.

به منظور تعیین سهم دقیق هر یک از ۲۳ عامل محیطی در پیش‌بینی زمین‌لغزش، از آزمون جک‌نایف^۱ (Boos & Brownie, 2004) در نرم‌افزار ModEco استفاده شد (شکل ۴). سه عامل ارتفاع، سازند زمین‌شناسی و فاصله از مناطق مسکونی به‌عنوان کنترل‌کننده‌های اصلی شناسایی شدند که ترکیبی از شرایط طبیعی (توپوگرافی و زمین‌شناسی) و فشار انسانی است. یکی از عوامل تأثیرگذار در وقوع زمین‌لغزش در آبخیز زیارت، ارتفاع است که با نتایج پژوهش‌های پیشین تطابق دارد (Karaka, 2017; Kocaman & Gokceoglu, 2022; Kornejady et al., 2020; Pawluszek & Borkowski, 2017). بیشترین لغزش‌ها در محدوده ارتفاعی ۱۵۰۰ تا ۲۲۰۰ متر رخ داده است که با بیشینه بارش و شیب تند همراه است. با افزایش ارتفاع، میزان بارش و در نتیجه توان اشباع شدن خاک افزایش می‌یابد، که منجر به افزایش زمین‌لغزش‌ها می‌شود (Kornejady, 2013). این طبقه ارتفاعی با میانگین بارندگی سالانه بیش از ۵۵۰ میلی‌متر، شیب‌های تند بین ۲۵ تا ۴۰ درجه و غلبه سازندهای فرسایش‌پذیر شمشک و شیبست گرگان همراه است.



شکل ۴- نمودار جکنایف برای تعیین عوامل موثر بر وقوع زمین لغزش در آبخیز زیارت

Fig. 4. Jackknife Diagram of Factors Influencing Landslide Occurrence in the Ziarat Watershed

نتایج پژوهش‌های مشابه در مناطق کوهستانی نیز نشان داده است که ارتفاع به دلیل کنترل توزیع بارش و دما، یکی از عوامل کلیدی در پهنه‌بندی حساسیت زمین لغزش محسوب می‌شود (Kornejady et al., 2020). با افزایش ارتفاع، میزان بارندگی افزایش یافته و در نتیجه رطوبت خاک بالا رفته و فشار آب حفره‌ای افزایش می‌یابد. این امر باعث کاهش مقاومت برشی خاک، به ویژه در لایه‌های شیل سازند شمشک، و در نهایت وقوع لغزش می‌شود. در مقابل، در ارتفاعات پایین‌تر، شیب‌ها عمدتاً ملایم‌تر بوده و سازندهای مقاوم‌تری مانند مبارک و خوش‌بیلاق رخنمون دارند، به همین دلیل تراکم لغزش در این مناطق به مراتب کمتر است. این الگو با نتایج پژوهش‌های پیشین در حوزه آبخیز چهل‌چای و اوغان در استان گلستان که تراکم لغزش را در ارتفاعات میانی و بالادست آبخیز گزارش کرده‌اند، همسو است (Kornejady & Pourghasemi, 2019; Kornejady et al., 2020). زمین‌شناسی عامل مؤثر دیگری است که با نتایج پژوهش‌های پیشین در زمین لغزش‌های مطالعه شده در استان گلستان هم‌راستا می‌باشد (Kornejady et al., 2020; Emadodin et al., 2021). از میان واحدهای سنگ‌شناسی موجود در این آبخیز، بیشترین تراکم زمین لغزش مربوط به سازند شمشک و مجموعه شیست گرگان است که بخش قابل توجهی از مساحت آبخیز را پوشش می‌دهند. سازند شمشک عمدتاً از شیل‌های سیلیتی و ماسه‌سنگ تشکیل شده است. لایه‌های شیل در این سازند به دلیل ماهیت رسی و جذب آب بالا، نقش اصلی را در وقوع لغزش‌های سطحی و چرخشی ایفا می‌کنند (Kornejady et al., 2020; Pourghasemi et al., 2012). مجموعه شیست گرگان نیز از شیست‌های میکادار و کلریتی با برگوارگی شدید تشکیل شده است که هوازگی سریع و ایجاد سطوح ضعف در دامنه‌ها را به دنبال دارد. این یافته با نتایج پژوهش‌های مشابه در استان گلستان که سازندهای شمشک و شیست گرگان را حساس‌ترین واحدهای سنگ‌شناسی در برابر زمین لغزش معرفی کرده‌اند، همخوانی دارد (Kornejady & Pourghasemi, 2019; Faramarzi et al., 2023). در مقابل، سازندهای مقاوم‌تری نظیر مبارک (آهک و دولومیت) و خوش‌بیلاق (آهک) تراکم لغزش بسیار کمتری دارند. این موضوع در پژوهش‌های پیشین در حوزه آبخیز چهل‌چای تأیید شده است (Kornejady & Pourghasemi, 2019). عامل مؤثر دیگر، فاصله از مناطق مسکونی است که با نتایج پژوهش‌های پیشین مطابقت دارد (Yu et al., 2023; Kalantar et al., 2020). تحلیل توزیع مکانی لغزش‌ها نشان داد که بسیاری از زمین لغزش‌ها در شعاع نزدیک روستای زیارت رخ داده‌اند. به طور کلی دستکاری در طبیعت بدون توجه به شرایط منطقه، موجب تحریک شدن و وقوع زمین لغزش خواهد شد. در آبخیز زیارت، لغزش‌ها در فواصل نزدیک به محدوده‌های مسکونی دیده شدند که نشان از فشار انسانی شامل برداشت خاک، ساخت‌وسازهای

غیراصولی و تخریب پوشش گیاهی دارد. مطالعات پیشین در استان گلستان نیز مداخلات انسانی (تغییر کاربری اراضی، جاده‌سازی و ساخت‌وساز) را به عنوان یکی از عوامل تشدیدکننده زمین‌لغزش معرفی کرده‌اند (Pourghasemi et al., 2012; Faramarzi et al., 2023; Kornejady et al., 2020).

در شکل ۵ که در بازدیدهای میدانی از حوزه آبخیز زیارت تهیه شده‌اند عوامل مؤثر در وقوع زمین‌لغزش مشخص هستند.



شکل ۵- زمین‌لغزش‌های رخ داده در حوزه آبخیز زیارت
Fig. 5. Landslides occurred in Ziarat Watershed

نتیجه‌گیری

در این پژوهش، کارایی سه مدل یادگیری ماشین شامل شبکه عصبی مصنوعی، ماشین بردار پشتیبان و بیشینه آنتروپی در پهنه‌بندی حساسیت زمین‌لغزش حوزه آبخیز زیارت ارزیابی و مقایسه شد. یافته‌ها نشان داد که مدل‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی عملکرد بسیار نزدیک و خوبی دارند، اما مقاومت بیشتر مدل ماشین بردار پشتیبان در برابر بیش‌برازش و دقت بالاتر آن در پیش‌بینی نقاط لغزش در طبقات پرخطر، این مدل را برای منطقه مورد مطالعه مناسب‌تر می‌سازد. بر خلاف بسیاری از مطالعات که تنها بر دقت مدل تأکید دارند، این پژوهش نشان داد که در شرایط پیچیده ژئومورفولوژیک حوزه آبخیز زیارت، انتخاب مدل باید مبتنی بر تعادل بین دقت پیش‌بینی و پایداری در برابر تغییرات داده باشد. از میان عوامل کنترل‌کننده سه

عامل مهم مؤثر در وقوع زمین لغزش شامل، ارتفاع (طبقه ارتفاعی ۱۵۰۰ تا ۲۲۰۰ متر به دلیل همگرایی بارش مؤثر، شیب تند)، سازند زمین شناسی (حضور سازندهای حساس شمشک و شیست گرگان)، فاصله از مناطق مسکونی می باشد. این یافته از آن جهت اهمیت دارد که نشان می دهد در حوزه آبخیز زیارت، مدیریت زمین لغزش صرفاً با رویکردهای طبیعی-محور ممکن نیست و کاهش فشار انسانی شامل برداشت خاک، ساخت وسازه های غیر اصولی و تخریب پوشش گیاهی باید به عنوان بخشی جدایی ناپذیر از راهکارهای کاهش خطر در نظر گرفته شود. بر اساس یافته های این پژوهش، سه پیامد عملی قابل ارائه است. نخست، نقشه حساسیت به دست آمده از مدل ماشین بردار پشتیبان می تواند مبنای بازنگری در طرح های توسعه روستایی در حوزه آبخیز زیارت قرار گیرد. دوم، اولویت بندی اقدامات تثبیت دامنه باید در ارتفاعات میانی و بالادست آبخیز و در شعاع نزدیک به سکونتگاه های اصلی متمرکز شود. سوم، هرگونه تغییر کاربری اراضی در دامنه های با شیب تند و سازندهای شمشک و شیست گرگان باید با محدودیت جدی مواجه شود. برای مطالعات آتی، استفاده از مدل های هیبریدی مبتنی بر ترکیب الگوریتم های یادگیری ماشین و شبکه های یادگیری عمیق برای بهبود دقت پیش بینی زمین لغزش توصیه می شود. به طور کلی، این پژوهش نشان داد که ترکیب مدل های یادگیری ماشین با تحلیل بومی عوامل محیطی و انسانی، می تواند ابزار مؤثری برای مدیریت خطر زمین لغزش در حوضه های کوهستانی ایران فراهم آورد.

References

- Ado, M., Amitab, K., Maji, A. K., Jasińska, E., Gono, R., Leonowicz, Z., & Jasiński, M. (2022). Landslide Susceptibility Mapping Using Machine Learning: A Literature Survey. *Remote Sensing*, 14(13), 3029. <https://doi.org/10.3390/rs14133029>
- Arabameri, A., Rezaei, K., Yamani, M., & Shirani, K. (2020). Performance assessment of integrated model of data driven EBF model and knowledge driven AHP model in Landslide spatial modeling (Case study: Ferydoun Shahr watershed). *Journal of Water and Soil Conservation Research*, 25(5), 47–67. [In Persian] <https://doi.org/10.22069/jwsc.2019.14338.2907>
- Babarabi, N., Lorestani, Gh., & Esmaili, R. (2025). Landslide hazard zoning using random forest and support vector machine models (Case study: Talar basin). *Researches in Earth Sciences*, 16(1), 152–168. [In Persian] <https://doi.org/10.48308/esrj.2025.236839.1234>
- Bahmani, S., Zangneh Tabar, Z., Mohammadi, S., & Matai, S. (2021). Identification and zoning of landslide prone areas using object-oriented method and network analysis (ANP) (Case study: Shahroudchai catchment area of Khalkhal city). *Geography and Environmental Hazards*, 10(3), 39–59. [In Persian] <https://dx.doi.org/10.22067/geoech.2021.67924.1006>
- Beven, K. J., & Kirkby, M. J. (1979). A physically based, variable contributing area model of basin hydrology. *Hydrological Sciences Bulletin*, 24(1), 43–69. <https://doi.org/10.1080/02626667909491834>
- Boos, D. D., & Brownie, C. (2004). Comparing variances and other measures of dispersion. *Statistical Science*, 19, 571–578. <https://doi.org/10.1214/088342304000000503>
- Chen, W., Pourghasemi, H. R., Kornejady, A., & Zhang, N. (2017). Landslide spatial modeling: introducing new ensembles of ANN, MaxEnt, and SVM machine learning techniques. *Geoderma*, 305, 314–327. <https://doi.org/10.1016/j.geoderma.2017.06.020>
- Dastranj, A., & Karimi Sangchini, E. (2022). Landslide susceptibility predicting using the maximum entropy machine learning algorithm (Bar catchment of Nishapur). *Earth Science Research Journal*, 13(51), 79–96. [In Persian] <https://doi.org/10.48308/esrj.2022.102965>
- Dastranj, A., Karimi Sangchini, E., & Noor, H. (2024). Landslide risk assessment in the Bar watershed, Neyshabur, Razavi Khorasan Province. *Iranian Journal of Watershed Management Science and Engineering*, 18(67), 44–60. [In Persian] <https://doi.org/10.22034/18.67.4>

- Emadodin, S., Taheri, V., Mohamadghasemi, M., & Nazari, Z. (2021). Landslide Susceptibility Zonation applying frequency ratio models and statistical index in in Oghan watershed. *Quantitative Geomorphological Research*, 9(4), 75–95. [In Persian] <https://doi.org/10.22034/gmpj.2021.248268.1211>
- Faramarzi, H., Hosseini, S. M., Pourghasemi, H. R., & Farnaghi, M. (2023). Using machine learning techniques in multi-hazards assessment of Golestan National Park, Iran. *Natural Hazards*, 117(3), 3231-3255. <https://doi.org/10.1007/s11069-023-05984-1>
- Fathiganji, R., Nazari Samani, A. A., Feiznia, S., & Nourizdan, A. (2024). Evaluating the role of geomorphic characteristics in landslide vulnerability and sensitivity (Case study: Kakasharaf Drainage Basin, Lorestan Province. *Natural Environment*, 77(4), 731–747. [In Persian] <http://doi.org/10.22059/jne.2024.376982.2675>
- Forte, G., Verrucci, L., Di Giulio, A., De Falco, M., Tommasi, P., Lanzo, G., ... & Santo, A. (2021). Analysis of major rock slides that occurred during the 2016–2017 Central Italy seismic sequence. *Engineering Geology*, 290, 106194. <https://doi.org/10.1016/j.enggeo.2021.106194>
- Froude, M. J., & Petley, D. N. (2018). Global fatal landslide occurrence from 2004 to 2016. *Natural Hazards and Earth System Sciences*, 18(8), 2161-2181. <https://doi.org/10.5194/nhess-18-2161-2018>
- Gariano, S. L., & Guzzetti, F. (2016). Landslides in a changing climate. *Earth-Science Reviews*, 162, 227-252. <https://doi.org/10.1016/j.earscirev.2016.08.011>
- Ghanavati, E., Ahmadabadi, A., & Gholami, M. (2019). Landslide susceptibility mapping of Kan using index of Entropy and LSM. *Quantitative Geomorphological Research*, 8(1), 16–33. [In Persian] <https://doi.org/10.22067/geoh.2025.89542.1514>
- Ghiasi, S. S., Rajabzadeh, F., Najirad, S., Feiznia, S., & Nazari Samani, A. A. (2017). Determining effective factors in the occurrence of shallow landslides in the Khirov-chai watershed. *Watershed Engineering and Management*, 9(2), 140–154. [In Persian] <https://doi.org/10.22092/ijwmse.2017.109697>
- Gilanipoor, A., Motevali, S., & Derafshi, K. (2025). Assessment of landslide sensitivity and determination of effective factors in its occurrence using the random forest algorithm (Case study: Glandrood watershed). *Journal of Geography and Environmental Hazards*, 14(1), 247-274. [In Persian] <https://doi.org/10.22067/geoh.2025.89542.1514>
- Guns, M., & Vanacker, V. (2014). Shifts in landslide frequency-area distribution after forest conversion in the tropical Andes. *Anthropocene*, 6, 75–85. <https://doi.org/10.1016/j.ancene.2014.08.001>
- Hamidi, M., Bouramtane, T., Abraham, S., Kacimi, I., Barbiero, L., Kassou, N., ... & Levy, G. (2023). Landslide hazard assessment in the heterogeneous geomorphological and environmental context of the rif region, Morocco– A machine learning approach. *Ecological Engineering & Environmental Technology*, 24, 272-292. <https://doi.org/10.12912/27197050/172569>
- Hanifinia, A. A., & Nazarnejad, H. (2022). The Effect of Morphometry Indices on Improving the Performance of Data Mining Models for Landslide Sensitivity Zoning in Cheriabad Watershed, Urmia. *Geography and Environmental Hazards*, 10(40), 47-68. [In Persian] <https://dx.doi.org/10.22067/geoh.2021.69707.1041>
- Harmouzi, H., Nefeslioglu, H. A., Rouai, M., Sezer, E. A., Dekayir, A., & Gokceoglu, C. (2019). Landslide susceptibility mapping of the Mediterranean coastal zone of Morocco between Oued Laou and El Jebha using artificial neural networks (ANN). *Arabian Journal of Geosciences*, 12(22), 696. <https://doi.org/10.1007/s12517-019-4892-0>
- Hemasinghe, H., Rangali, R. S. S., Deshapriya, N. L., & Samarakoon, L. (2018). Landslide susceptibility mapping using logistic regression model (a case study in Badulla District, Sri Lanka). *Procedia Engineering*, 212, 1046-1053. <https://doi.org/10.1016/j.proeng.2018.01.135>
- Hong, H., Pradhan, B., Xu, C., & Bui, D. T. (2015). Spatial prediction of landslide hazard at the Yihuang area (China) using two-class kernel logistic regression, alternating decision tree and support vector machines. *Catena*, 133, 266-281. <https://doi.org/10.1016/j.catena.2015.05.019>

- Kalantar, B., Ueda, N., Saeidi, V., Ahmadi, K., Halin, A. A., & Shabani, F. (2020). Landslide susceptibility mapping: machine and ensemble learning based on remote sensing big data. *Remote Sensing*, 12(11), 1737. <https://doi.org/10.3390/rs12111737>
- Karakas, G., Kocaman, S., & Gokceoglu, C. (2022). On the effect of DEM quality for landslide susceptibility mapping. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 3, 525-531. <https://doi.org/10.5194/isprs-annals-V-3-2022-525-2022>
- Karami, F., Bayati Khatibi, M., Kheirizadeh, M., & Mokhtari Asl, A. (2019). Evaluation of Performance of Support Vector Machine Algorithm in Landslide Susceptibility Zoning in Ahar-chai Basin. *Geography and Environmental Hazards*, 8(4), 1–17. [In Persian] <https://doi.org/10.22067/geo.v8i4.83263>
- Kirschbaum, D., Stanley, T., & Zhou, Y. (2015). Spatial and temporal analysis of a global landslide catalog. *Geomorphology*, 249, 4-15. <https://doi.org/10.1016/j.geomorph.2015.03.016>
- Kornejady, A. (2013). *Landslide hazard, damage assessment, and management planning in the Ziarat watershed*. (Master's Thesis). Gorgan University of Agricultural Sciences and Natural Resources, Iran. [In Persian]
- Kornejady, A., & Pourghasemi, H. R. (2019). Landslide susceptibility assessment using data mining models, a case study: Chehel-Chai Basin. *Watershed Engineering and Management*, 11(1), 28-42. [In Persian] <https://doi.org/10.22092/ijwmse.2019.118436>
- Kornejady, A., Ownegh, M., Pourghasemi, H. R., Bahremand, A., & Motamedi, M. (2020). Landslide susceptibility prediction using the coupled Mahalanobis distance and machine learning models (case study: Owghan watershed, Golestan province. *Researches in Earth Science*, 11(2), 1–18. [In Persian] <https://doi.org/10.52547/esrj.11.2.1>
- Lee, S. A. R. O. (2005). Application of logistic regression model and its validation for landslide susceptibility mapping using GIS and remote sensing data. *International Journal of Remote Sensing*, 26(7), 1477-1491. <https://doi.org/10.1080/01431160412331331012>
- Maki Mateso, J. C., Biellers, C. L., Monsieurs, E., Depicker, A., Smets, B., Tambala, T., ... & Dewitte, O. (2023). Characteristics and causes of natural and human-induced landslides in a tropical mountainous region: the rift flank west of Lake Kivu (Democratic Republic of the Congo). *Natural Hazards and Earth System Sciences*, 23(2), 643-666. <https://doi.org/10.5194/nhess-23-643-2023>
- Mao, Y., Li, Y., Teng, F., Sabonchi, A. K., Azarafza, M., & Zhang, M. (2024). Utilizing hybrid machine learning and soft computing techniques for landslide susceptibility mapping in a drainage basin. *Water*, 16(3), 380. <https://doi.org/10.3390/w16030380>
- 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/geoh.2025.92634.1557>
- Nanehkaran, Y. A., Chen, B., Cemiloglu, A., Chen, J., Anwar, S., Azarafza, M., & Derakhshani, R. (2023). Riverside landslide susceptibility overview: leveraging artificial neural networks and machine learning in accordance with the United Nations (UN) sustainable development goals. *Water*, 15(15), 2707. <https://doi.org/10.3390/w15152707>
- Nanehkaran, Y. A., Mao, Y., Azarafza, M., Kockar, M. K., & Zhu, H. H. (2021). Fuzzy-based multiple decision method for landslide susceptibility and hazard assessment: A case study of Tabriz, Iran. *Geomechanics and Engineering*, 24(5), 407-418. <https://doi.org/10.12989/gae.2021.24.5.407>
- Nikoobakht, S., Azarafza, M., Akgün, H., & Derakhshani, R. (2022). Landslide susceptibility assessment by using convolutional neural network. *Applied Sciences*, 12(12), 5992. <https://doi.org/10.3390/app12125992>
- Ozturk, U., Bozzolan, E., Holcombe, E. A., Shukla, R., Pianosi, F., & Wagener, T. (2022). How climate change and unplanned urban sprawl bring more landslides. *Nature*, 608(7922), 262-265. <https://doi.org/10.1038/d41586-022-02141-9>

- Park, S., & Kim, J. (2019). Landslide susceptibility mapping based on random forest and boosted regression tree models, and a comparison of their performance. *Applied Sciences*, 9(5), 942. <https://doi.org/10.3390/app9050942>
- Pawluszek, K., & Borkowski, A. (2017). Impact of DEM-derived factors and analytical hierarchy process on landslide susceptibility mapping in the region of Rożnów Lake, Poland. *Natural Hazards*, 86(2), 919-952. <https://doi.org/10.1007/s11069-016-2725-y>
- Petley, D. (2012). Global patterns of loss of life from landslides. *Geology*, 40(10), 927-930. <https://doi.org/10.1130/G33217.1>
- Pham, B. T., Pradhan, B., Bui, D. T., Prakash, I., & Dholakia, M. B. (2016). A comparative study of different machine learning methods for landslide susceptibility assessment: A case study of Uttarakhand area (India). *Environmental Modelling & Software*, 84, 240-250. <https://doi.org/10.1016/j.envsoft.2016.07.005>
- Phong, T. V., Phan, T. T., Prakash, I., Singh, S. K., Shirzadi, A., Chapi, K., ... & Pham, B. T. (2021). Landslide susceptibility modeling using different artificial intelligence methods: A case study at Muong Lay district, Vietnam. *Geocarto International*, 36(15), 1685-1708. <https://doi.org/10.1080/10106049.2019.1665715>
- Pontius Jr, R. G., & Schneider, L. C. (2001). Land-cover change model validation by an ROC method for the Ipswich watershed, Massachusetts, USA. *Agriculture, Ecosystems & Environment*, 85(1-3), 239-248. [https://doi.org/10.1016/S01678809\(01\)00187-6](https://doi.org/10.1016/S01678809(01)00187-6)
- Pourghasemi, H. R., Pradhan, B., Gokceoglu, C., & Deylami Moezzi, K. (2012). Landslide susceptibility mapping using a spatial multi criteria evaluation model at Haraz Watershed, Iran. In *Terrigenous mass movements: detection, modelling, early warning and mitigation using geoinformation technology* (pp. 23-49). Berlin, Heidelberg: Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-25495-6_2
- Pyakurel, A., Dahal, B. K., & Gautam, D. (2023). Does machine learning adequately predict earthquake induced landslides?. *Soil Dynamics and Earthquake Engineering*, 171, 107994. <https://doi.org/10.1016/j.soildyn.2023.107994>
- Saberchenari, K., Salmani, H., & Mirabedini, M. (2018). Landslide hazard mapping using Dempster-Shafer theory - A case study: Ziarat Watershed, Golestan Province, Iran. *Journal of Engineering Geology*, 11(4), 385-404. <https://doi.org/10.18869/acadpub.jeg.11.4.385>
- 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*, 14(45), 133-154. <https://doi.org/10.22111/jneh.2025.50031.2071>
- Santangelo, N., Forte, G., De Falco, M., Chirico, G. B., & Santo, A. (2021). New insights on rainfall triggering flow-like landslides and flash floods in Campania (Southern Italy). *Landslides*, 18(8), 2923-2933. <https://doi.org/10.1007/s10346-021-01667-9>
- Saro, L., Woo, J. S., Kwan-Young, O., & Moung-Jin, L. (2016). The spatial prediction of landslide susceptibility applying artificial neural network and logistic regression models: A case study of Inje, Korea. *Open Geosciences*, 8(1), 117-132. <https://doi.org/10.1515/geo-2016-0010>
- Selamat, S. N., Abd Majid, N., & Mohd Taib, A. (2023). A comparative assessment of sampling ratios using artificial neural network (ANN) for landslide predictive model in Langat River Basin, Selangor, Malaysia. *Sustainability*, 15(1), 861. <https://doi.org/10.3390/su15010861>
- Sepahvand, A. R., & Beiranvand, N. (2024). Landslide susceptibility mapping using various soft computing techniques (Case study: A part of Haraz Watershed). *Water and Soil Management and Modelling*, 4(2), 261-278. <https://doi.org/10.22098/mmws.2023.12678.1263>
- Sun, D., Xu, J., Wen, H., & Wang, D. (2021). Assessment of landslide susceptibility mapping based on Bayesian hyperparameter optimization: A comparison between logistic regression and random forest. *Engineering Geology*, 281, 105972. <https://doi.org/10.1016/j.enggeo.2020.105972>

- Suyarto, R., Diara, I. W., Susila, K. D., Saifulloh, M., Wiyanti, W., Kusmiyarti, T. B., & Sunarta, I. N. (2023). Landslide inventory mapping derived from multispectral imagery by support vector machine (SVM) algorithm. In *IOP Conference Series: Earth and Environmental Science*, 1190(1), 012012. <https://doi.org/10.1088/1755-1315/1190/1/012012>
- Trigila, A., Iadanza, C., Esposito, C., & Scarascia-Mugnozza, G. (2015). Comparison of Logistic Regression and Random Forests techniques for shallow landslide susceptibility assessment in Giampilieri (NE Sicily, Italy). *Geomorphology*, 249, 119-136. <https://doi.org/10.1016/j.geomorph.2015.06.001>
- Wang, Y., Fang, Z., Wang, M., Peng, L., & Hong, H. (2020). Comparative study of landslide susceptibility mapping with different recurrent neural networks. *Computers & Geosciences*, 138, 104445. <https://doi.org/10.1016/j.cageo.2020.104445>
- Yao, J., Qin, S., Qiao, S., Liu, X., Zhang, L., & Chen, J. (2022). Application of a two-step sampling strategy based on deep neural network for landslide susceptibility mapping. *Bulletin of Engineering Geology and the Environment*, 81(4), 148. <https://doi.org/10.1007/s10064-022-02615-0>
- Yeon, Y. K., Han, J. G., & Ryu, K. H. (2010). Landslide susceptibility mapping in Injae, Korea, using a decision tree. *Engineering Geology*, 116(3-4), 274-283. <https://doi.org/10.1016/j.enggeo.2010.09.009>
- Yu, H., Pei, W., Zhang, J., & Chen, G. (2023). Landslide susceptibility mapping and driving mechanisms in a vulnerable region based on multiple machine learning models. *Remote Sensing*, 15(7), 1886. <https://doi.org/10.3390/rs15071886>
- Zevenbergen, L. W., & Thorne, C. R. (1987). Quantitative analysis of land surface topography. *Earth Surface Processes and Landforms*, 12(1), 47-56. <https://doi.org/10.1002/esp.3290120107>
- Zhao, Z., Liu, Z. Y., & Xu, C. (2021). Slope unit-based landslide susceptibility mapping using certainty factor, support vector machine, random forest, CF-SVM and CF-RF models. *Frontiers in Earth Science*, 9, 589630. <https://doi.org/10.3389/feart.2021.589630>