

Application of artificial intelligence in preparing gully erosion susceptibility maps in the Alshater County, Lorestan Province

Negar Arjmand¹, Alireza Sepahvand^{2*} and Omid Rahmati³

¹ Ph.D. Student, Department of Range and Watershed Management, Faculty of Natural Resources, Lorestan University, Khorramabad, Lorestan Province, Iran

² Associate Professor, Department of Range and Watershed Management Engineering, Faculty of Natural Resources, Lorestan University, Khorramabad, Lorestan Province, Iran

³ Assistant Professor, Soil Conservation and Watershed Management Research Department, Kurdistan Agricultural and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization (AREEO), Sanandaj, Iran

Received: 11 November 2025

Accepted: 18 April 2026

Extended abstract

Introduction

Today, the study of gully erosion is of great importance due to sediment production and numerous damages resulting from human activities. Many natural factors have been reported as controlling factors of gully erosion. Among the geo-environmental factors that control the critical conditions for the occurrence and development of gully erosion, primarily related to topography, lithology, rainfall, soil, and land use, other studies have stated that surface runoff is one of the main factors affecting the occurrence of gully erosion. Identifying the factors affecting the occurrence of gully erosion and its zoning is one of the essential and important tools for controlling and managing this phenomenon. Gully erosion is a significant threat to the state of ecosystems worldwide; consequently, developing gully erosion susceptibility maps is essential. Therefore, this research was conducted to mapping the susceptibility of gully erosion occurrence using artificial intelligence models of the Multilayer Perceptron (MLP) neural network, Maximum Entropy (MaxEnt), and Flexible Discriminant Analysis (FDA) in Al-Shatr city.

Materials and methods

The study area is located in the central part of the Zagros mountain range in Lorestan Province, Iran, within the Karkheh sub-basin. Alashtar County covers an area of 1,523.55 km², situated between longitudes 48°30'52"E to 48°03'38"E and latitudes 34°01'21"N to 33°44'37"N. The basin has an average annual precipitation of approximately 570 mm and features a semi-arid, cold climate. To map gully erosion susceptibility and identify the most effective model, three artificial intelligence models were employed: Multi-Layer Perceptron (MLP), Maximum Entropy (MaxEnt), and Flexible Discriminant Analysis (FDA). Twelve environmental factors were used as input variables: slope, aspect, precipitation, distance from roads, distance from rivers, distance from faults, soil type, land use, geological formation, Topographic Wetness Index (TWI), Topographic Position Index (TPI), and Normalized Difference Vegetation Index (NDVI). The output variables consisted of gully and non-gully points. A total of 151 points (89 gully and 62 non-gully locations) were collected. Seventy percent of the data were used for model training, while the remaining 30% were reserved for validation. Model performance was evaluated using the Relative Operating Characteristic (ROC) curve to assess predictive accuracy.

Results and discussion

The results showed that the MLP model, with AUC values of 0.98 in the training phase and 0.92 in the validation phase, had the best performance in predicting gully erosion susceptibility. This was followed by the FDA (AUC = 0.87) and MaxEnt (AUC = 0.5) models, respectively. Analysis of the influencing factors revealed that most gullies were located in precipitation classes of 600-700 mm, distances greater than 300 meters from faults, roads, and rivers, slope classes of 0-5% and 5-15%, northern aspects, dry farming land use, and geological formations of old alluvium and marls. Furthermore, a direct relationship was observed between the TWI index and gully occurrence, while an inverse relationship was found for the NDVI index. Finally, the gully erosion map was prepared using the MLP model.

* Corresponding author: sepahvand.a@lu.ac.ir

Conclusions

Given that gully erosion is an advanced form of water erosion, identifying its driving factors and mapping its susceptibility are crucial for effective control and management. This study aimed to identify key factors influencing gully erosion and develop machine learning models to map susceptibility in Shastar County. Results indicate that the Artificial Neural Network (MLP) model performed best, achieving an AUC of 0.92, followed by FDA (AUC = 0.87) and MaxEnt (AUC = 0.50). These findings provide valuable insights for planners and researchers regarding the factors driving gully erosion. Future research should explore additional machine learning techniques and incorporate other influential factors to further improve prediction accuracy.

Keywords: FDA Model, Lorestan province, Machine Learning, Mapping of gully erosion, Modeling

Cite this article: Arjmand, N., 2 Sepahvand, A., Rahmati, O., 026. Application of artificial intelligence in preparing gully erosion susceptibility maps in the Alshater County, Lorestan Province. Watershed. Water. Eng. Manag.18(2), 237-256.

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



کاربرد هوش مصنوعی در تهیه نقشه خطر فرسایش آبکند در شهرستان الشتر، استان لرستان

نگار ارجمند^۱، علیرضا سپه‌وند^{۲*} و امید رحمتی^۳

^۱ دانشجوی دکتری، گروه مهندسی مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه لرستان، خرم آباد، ایران

^۲ دانشیار، گروه مهندسی مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه لرستان، خرم آباد، ایران

^۳ استادیار، بخش تحقیقات حفاظت خاک و آبخیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان کردستان، سازمان تحقیقات آموزش و ترویج کشاورزی، سنندج، ایران

تاریخ پذیرش: ۲۹/۰۱/۱۴۰۵

تاریخ دریافت: ۲۰/۰۸/۱۴۰۴

چکیده مبسوط

مقدمه

امروزه مطالعه فرسایش خندقی به دلیل تولید رسوب و خسارات متعدد در نتیجه فعالیت‌های انسانی از اهمیت بالایی برخوردار است. در مطالعات انجام شده عوامل طبیعی زیادی به عنوان عوامل کنترل کننده فرسایش آبکندی گزارش شده‌اند که از جمله می‌توان به عوامل زمین-محیطی که شرایط بحرانی برای وقوع و توسعه فرسایش آبکندی را کنترل می‌کنند و در درجه اول با توپوگرافی، سنگ‌شناسی، بارندگی، خاک و کاربری اراضی مرتبط هستند اشاره کرد. شناسایی عوامل مؤثر در وقوع فرسایش آبکندی و پهنه‌بندی آن یکی از ابزارهای اساسی و مهم برای کنترل و مدیریت این پدیده است. فرسایش آبکندی یک خطر مهم برای وضعیت اکوسیستم‌ها در سراسر جهان است، در نتیجه توسعه نقشه‌های حساسیت فرسایش آبکندی ضروری است. بنابراین این پژوهش به منظور پهنه‌بندی حساسیت وقوع فرسایش آبکندی با استفاده از مدل‌های هوش مصنوعی از نوع شبکه عصبی مصنوعی (MLP)، حداکثر آنتروپی (MaxEnt)، تحلیل تفکیک کننده انعطاف پذیر (FDA)، در شهرستان الشتر انجام شد.

مواد و روش‌ها

منطقه مورد مطالعه از نظر ژئومورفولوژیکی در بخش مرکزی رشته کوه زاگرس در استان لرستان قرار دارد که خود بخشی از زیرحوضه کرخه است. شهرستان الشتر با مساحت ۱۵۲۳/۵۵ کیلومتر مربع بین طول‌های جغرافیایی ۳۸° ۳' ۴۸" تا ۳۸° ۳۰' ۵۲" شرقی و عرض‌های ۳۳° ۴۴' ۳۷" تا ۳۴° ۰۱' ۲۱" شمالی قرار دارد. میانگین بارندگی حوضه حدود ۵۷۰ میلی‌متر و دارای اقلیم نیمه‌خشک و سرد است. برای پهنه‌بندی حساسیت به وقوع فرسایش خندقی با استفاده از مدل‌های هوش مصنوعی و تعیین بهترین مدل، از مدل‌های شبکه عصبی مصنوعی (MLP) حداکثر آنتروپی (MaxEnt)، تحلیل تفکیک کننده انعطاف پذیر (FDA)، استفاده شد. در این تحقیق از ۱۲ عامل شیب، جهت شیب، بارش، فاصله از جاده، فاصله از رودخانه، فاصله از گسل، خاک، کاربری اراضی، سازند زمین‌شناسی، شاخص رطوبت توپوگرافی (TWI)، شاخص موقعیت توپوگرافی TPI و شاخص پوشش گیاهی NDVI به عنوان پارامترهای ورودی و نقاط خندقی و غیرخندقی به عنوان پارامترهای خروجی برای مدلسازی و پهنه‌بندی حساسیت به وقوع خندق استفاده شد. سپس از مجموع ۱۵۱ نقطه وقوع و عدم وقوع خندق (۸۹ خندق و ۶۲ غیر خندق)، ۷۰ درصد به عنوان داده‌های آموزش و ۳۰ درصد برای

* مسئول مکاتبات: sepahvand.a@lu.ac.ir

مرحله اعتبارسنجی استفاده شد. به منظور ارزیابی مدل‌ها، از منحنی تشخیص عملکرد نسبی (ROC) برای قدرت پیش‌بینی مدل‌ها استفاده شد.

نتایج و بحث

نتایج نشان داد که مدل MLP با مقادیر AUC برابر با ۰/۹۸ در مرحله آموزش و ۰/۹۲ در مرحله اعتبارسنجی، بهترین عملکرد را در پیش‌بینی حساسیت وقوع فرسایش آب‌کندی دارد. پس از آن به ترتیب مدل‌های (AUC=۰/۸۷) FDA و (AUC=۰/۵) MaxEnt قرار دارند. تحلیل عوامل مؤثر نشان داد که بیشترین آب‌کندها در طبقات بارشی ۶۰۰-۷۰۰ میلی‌متر، فواصل بیش از ۳۰۰ متر از گسل، جاده و رودخانه، شیب‌های ۵-۰ و ۱۵-۵ درصد، جهت‌های شمالی، کاربری کشاورزی دیم و سازندهای آبرفت قدیم و مارن‌ها واقع شده‌اند. همچنین بین شاخص‌های TWI و NDVI به ترتیب رابطه مستقیم و معکوس با وقوع آب‌کندها مشاهده شد. در نهایت، نقشه نهایی پهنه‌بندی حساسیت فرسایش آب‌کندی با استفاده از مدل برتر MLP تهیه شد.

نتیجه‌گیری

با توجه به اینکه فرسایش آب‌کندی یکی از شکل‌های پیشرفته فرسایش آبی است، شناسایی عوامل مؤثر و پهنه‌بندی آن برای کنترل و مدیریت این پدیده حائز اهمیت است. این مطالعه با هدف شناسایی عوامل مهم و تأثیرگذار در فرسایش آب‌کندی و ایجاد مدل‌های یادگیری ماشین برای پهنه‌بندی حساسیت وقوع به فرسایش آب‌کندی در شهرستان الشتر انجام شد. نتایج نشان داد که مدل شبکه عصبی مصنوعی (MLP) بهترین عملکرد را با توجه به معیار ارزیابی مدل (AUC=۰/۹۲) کسب کرده است و پس از آن به ترتیب مدل‌های (AUC=۰/۸۷) FDA و (AUC=۰/۵) MaxEnt قرار دارند. نتایج به‌دست‌آمده از این پژوهش، دیدگاه مناسبی را در مورد تأثیر عوامل مؤثر در ایجاد فرسایش خندقی در اختیار برنامه‌ریزان و محققان قرار می‌دهد. در نتیجه با انجام تحقیقات بیشتر می‌توان استفاده از سایر تکنیک‌های یادگیری ماشین را بررسی نمود و دیگر عوامل مؤثر را برای بهبود دقت مدل‌های پیش‌بینی فرسایش خندقی در نظر گرفت.

واژه‌های کلیدی: استان لرستان، پهنه‌بندی وقوع فرسایش آب‌کندی، مدل‌سازی، مدل FDA، یادگیری ماشین

مقدمه

است و باعث می‌شود خطوط زهکشی با آب لبریز شوند و در مناطق آسیب‌پذیر، آب‌کندهایی تشکیل شود (et al., 2020). بنابراین، حفظ خاک از انواع مختلف فرسایش و کاهش پدیده گسترش‌یافته تخریب زمین اهمیت دارد (Arabameri et al., 2020a).

آب‌کندها از پیچیده‌ترین شکل‌های فرسایش خطی هستند که در اثر عوامل مختلفی طی چندین مرحله و در طول زمان، گسترش پیدا می‌کنند. فرسایش آب‌کندی یکی از فرایندهای تخریب زمین است و به عنوان پیچیده‌ترین پدیده فرسایش خاک عمل می‌کند (Poesen et al., 1988; Valentin et al., 2005; Borrelli et al., 2020). عوامل طبیعی زیادی به عنوان عوامل کنترل کننده فرسایش آب‌کندی گزارش شده‌اند. عوامل طبیعی زیادی به عنوان عوامل کنترل کننده فرسایش آب‌کندی گزارش شده‌اند. همان‌طور که در

فرسایش به عنوان یکی از عوامل تخریب محیطی، باعث از بین رفتن خاک، آلودگی منابع آب، کاهش نفوذپذیری خاک، تخریب اراضی مرتعی و جنگلی و غیره می‌شود. فرسایش خاک، به‌ویژه از طریق فرسایش آب‌کندی، به عنوان یک نگرانی محیط‌زیستی عمده پدیدار شده است که عمدتاً مناطق نیمه مرطوب تا خشک مدیترانه‌ای را تحت تأثیر قرار می‌دهد. این مشکل فقط به مزارع کشاورزی آسیب نمی‌زند، بلکه باعث رسوبگذاری و سایر مشکلات زیست‌محیطی نیز می‌شود (Kheir et al., 2007).

دلایل اصلی نبود پوشش خاک و ناتوانی خاک در جذب آب، کاربری نامناسب زمین، فشردگی خاک در اثر چرای بیش از حد دام و بسیاری از موارد دیگر است به همین دلیل، رواناب سطحی همچنان در حال افزایش

مطالعات پیشین نشان داده شده است، عوامل زمین‌محیطی مانند توپوگرافی، سنگ‌شناسی، بارندگی، خاک و کاربری اراضی، شرایط بحرانی را برای شکل‌گیری و توسعه فرسایش آبکندی کنترل می‌نمایند. در این میان، رواناب سطحی به عنوان یکی از عوامل اصلی مؤثر در وقوع این پدیده است (Poesen, 2011). مطالعه فرسایش آبکندی به دلیل تولید رسوب و خسارات متعدد در نتیجه فعالیت‌های انسانی از اهمیت بالایی برخوردار است. آبکندها معمولاً در پاسخ به ویژگی‌های توپوگرافی، اقلیمی و هیدرولوژیکی محلی ایجاد و تکامل می‌یابند (Chowdhuri et al., 2021). مدل‌های آماری مختلفی مبتنی بر داده‌های محیطی برای پیش‌بینی و پهنه‌بندی حساسیت فرسایش آبکندی استفاده شده‌اند. این مدل‌ها را می‌توان به سه گروه طبقه‌بندی کرد: مدل‌های یادگیری ماشین، مدل‌های فرایند تحلیل سلسله مراتبی^۱ و مدل‌های آماری دو متغیره و چند متغیره (Garosi et al., 2018؛ Zabihi et al., 2018؛ Arabmeri et al., 2019؛ Domazetovi et al., 2019؛ Lie et al., 2020؛ Soleimanpour et al., 2021). مدل‌های یادگیری ماشین شاخه‌ای از هوش مصنوعی و علوم کامپیوتر است که بر استفاده از داده‌ها و الگوریتم‌ها برای تقلید از روش یادگیری انسان‌ها تمرکز دارد تا به تدریج دقتش بهبود یابد. در این پژوهش از مدل‌های شبکه عصبی مصنوعی^۲، حداکثر آنتروپی^۳، تحلیل تفکیک‌کننده انعطاف‌پذیر^۴ استفاده شده است. در ایران و سایر نقاط جهان تحقیقات زیادی در رابطه با پهنه‌بندی حساسیت به وقوع فرسایش آبکندی انجام شده است. (Saeidian et al., 2023) به بررسی عملکرد مدل بیشینه آنتروپی در تعیین اهمیت عوامل مؤثر محیطی در ایجاد فرسایش آبکندی در مناطق نیمه خشک پرداختند. نتایج این تحقیق نشان داد که مهم‌ترین عوامل محیطی تأثیرگذار در فرسایش آبکندی در منطقه مورد مطالعه نوع اقلیم، سنگ‌شناسی، بارش و نوع خاک است.

Khazaei et al., (2024) به بررسی عوامل مؤثر بر فرسایش آبکندی و تهیه نقشه پهنه‌بندی در حوزه آبخیز تخت دراز پرداختند. نتایج آنها نشان داد که مدل آنتروپی با سطح زیر منحنی ۰/۸۸ دارای دقت پیش‌بینی مناسبی بوده است، و کاربری اراضی و زمین‌شناسی بیشترین اهمیت را در رخداد فرسایش آبکندی داشته‌اند. (Davoudi et al., 2025) به ارزیابی مناطق مستعد رخداد فرسایش خندقی در حوضه الشتر با استفاده از مدل‌های یادگیری ماشین پرداختند. در این تحقیق پارامترهای توپوگرافی، اقلیمی، هیدرولوژیکی، پوشش گیاهی، کاربری اراضی و ویژگی‌های فیزیکی و شیمیایی خاک با استفاده از سامانه اطلاعات جغرافیایی^۵ و داده‌های سنجش از دور استخراج شدند. همچنین از مدل‌های BLM^۶، GLM^۷ و BRT^۸ برای مدلسازی فرسایش خندقی استفاده شد. نتایج تحقیق نشان داد که مدل BLM عملکرد بهتری در شناسایی مناطق پرخطر فرسایش خندقی نسبت به مدل‌های GLM و BRT دارد. (TienBui et al., 2019) در پژوهشی با استفاده از ۱۹ شاخص مهم و تأثیرگذار پهنه‌بندی حساسیت فرسایش آبکندی با استفاده از شش مدل هیبریدی ترکیبی جدید یادگیری ماشین در استان کردستان اعلام نمودند که مدل ترکیبی RF-ADTree نسبت به سایر مدل‌ها بر اساس شاخص AUC برتری دارد. همچنین شاخص‌های فاصله از رودخانه، ژئومورفولوژی، کاربری اراضی، خاک، شیب و لیتولوژی را به عنوان مهم‌ترین عوامل تأثیرگذار بر فرسایش آبکندی تشخیص دادند.

Wang et al., (2021) به پیش‌بینی فرسایش آبکندی با استفاده از تأثیر نمونه‌گیری مجدد بر روی مدل‌های یادگیری ماشین در حوزه آبخیز کندوران در استان هرمزگان پرداختند و به این نتیجه رسیدند که استفاده از الگوریتم‌های نمونه‌گیری مجدد کارایی مدل‌ها را افزایش داده است. (Chuma et al., 2023) به ارزیابی اثربخشی چهار روش یادگیری ماشین جنگل تصادفی (RF)، حداکثر آنتروپی (MaxEn)، شبکه عصبی مصنوعی (MLP) و درخت رگرسیون

^۱ Hierarchical Analysis (AHP)

^۲ Artificial Neural Network Models (MLP)

^۳ Maximum Entropy (MaxEnt)

^۴ Flexible Discriminant Analysis (FDA)

^۵ Geographic Information System (GIS)

^۶ Boosted Linear Models

^۷ Generalized Linear Models

^۸ Boosted Regression Tree

منطقه مورد مطالعه: منطقه مورد مطالعه از نظر ژئومورفولوژیکی در بخش مرکزی رشته‌کوه زاگرس در استان لرستان قرار دارد که خود بخشی از زیر حوزه کرخه است. شهرستان الشتر با مساحت ۱۵۲۳/۵۵ کیلومتر مربع مطابق شکل ۱ بین طول‌های جغرافیایی ۳۸°۰۳' ۳۸" تا ۴۸°۰۳' ۵۲" شرقی و عرض‌های ۳۷° ۳۷' ۳۳" تا ۳۴° ۰۱' ۲۱" شمالی قرار دارد.

بلندترین نقطه حوضه در بخش شمال غربی با ارتفاع ۳۶۲۰ متر از سطح دریا و پست‌ترین نقطه حوضه در بخش غربی یعنی خروجی حوضه با ارتفاع ۱۴۸۱ متر از سطح دریا قرار دارد (شکل ۱). میانگین بارندگی حوضه حدود ۵۷۰ میلی‌متر و دارای اقلیم نیمه‌خشک و سرد است.

در ادامه با بررسی سوابق تحقیق و همچنین مشاهدات میدانی، عوامل مؤثر بر وقوع آبکندهای منطقه تعیین شدند و نقشه این عوامل برای استفاده در مدلسازی و پهنه‌بندی خطر وقوع آبکند تهیه شد. بر همین اساس برای تهیه نقشه پهنه‌بندی وقوع فرسایش آبکندهای با استفاده از مدل‌های هوش مصنوعی در منطقه مورد مطالعه از ۱۲ عامل شیب، جهت شیب، فاصله از آبراهه، فاصله از گسل، فاصله از جاده، خاک، سازند زمین‌شناسی، کاربری اراضی، بارش، شاخص رطوبت توپوگرافی^۴، شاخص موقعیت توپوگرافی^۴ و شاخص پوشش گیاهی NDVI استفاده شد. بدین منظور لایه‌های شیب و جهت، با استفاده از نقشه مدل رقومی ارتفاع^۵ تهیه شدند.

نقشه‌های زمین‌شناسی و فاصله از گسل از نقشه زمین‌شناسی منطقه با مقیاس ۱:۱۰۰۰۰۰ تهیه شد و نقشه جاده و آبراهه از سازمان زمین‌شناسی کشور فراهم شد و در ادامه نقشه‌های فاصله از جاده و فاصله از آبراهه تهیه شدند. همچنین نقشه کاربری اراضی از اداره کل منابع طبیعی استان لرستان تهیه شد. برای تهیه نقشه بارش، داده‌های بارش ایستگاه‌های هواشناسی خرم‌آباد، کوهدشت، الشتر، نورآباد، بروجرد، رومشگان، پلدختر و دورود از اداره کل هواشناسی استان لرستان، و سپس

تقویت‌شده^۱ برای شناسایی عوامل محرک فرسایش آبکندهای و پیش‌بینی حساسیت فرسایش آبکندهای پرداختند. نتایج نشان داد که الگوریتم‌های RF و MaxEnt به‌ترتیب با ۰/۸۲ و ۰/۸۰۴ دقت پیش‌بینی بالاتری نسبت به MLP و BRT داشتند. همچنین نتایج نشان داد که مدل‌های RF و MaxEnt دارای بیشترین دقت برای تعیین مناطق حساس به وقوع خندق در منطقه مورد مطالعه هستند.

Wang et al., (2024) به ارزیابی حساسیت فرسایش آبکندهای با استفاده از پهنه‌بندی و مدل‌های ترکیبی مبتنی بر یادگیری ماشین پرداختند. نتایج نشان داد که ال‌جی بالاترین دقت را در طبقه‌بندی پیکسل‌های آبکندهای پردازش کرده است و شیب دامنه، فاصله از جاده و چگالی زهکشی به‌طور قابل‌توجهی در وقوع فرسایش آبکندهای تأثیر گذاشتند. (Hasanuzzaman (2024) به بررسی و پهنه‌بندی حساسیت به وقوع فرسایش آبکندهای و اولویت‌بندی زیرحوزه‌های آبخیز غالب آبکندهای با استفاده از الگوریتم‌های یادگیری ماشین در رودخانه گرمسیری هند پرداختند. نتایج این تحقیق نشان داد که هر دو مدل XGBoost و RF عملکرد قوی دارند، به‌طوری که مدل‌های XGBoost و RF به‌ترتیب به مقادیر ROC ۸۴/۱ درصد و ۸۳/۲ درصد دست یافتند. (Gao et al., (2025) به پهنه‌بندی حساسیت فرسایش آبکندهای با در نظر گرفتن تغییرات فصلی شاخص^۲ با استفاده از رویکرد یادگیری ماشین در منطقه مالیسول چین پرداختند. نتایج نشان داد که شاخص NDVI بین مناطق دارای آبکند و غیر آبکند تفاوت زیادی دارد و اهمیت NDVI در ماه‌های مختلف متفاوت است. لذا با توجه به بررسی سوابق تحقیق و همچنین ضرورت انجام پهنه‌بندی و تهیه نقشه خطر وقوع آبکند، هدف اصلی این پژوهش، پهنه‌بندی حساسیت وقوع فرسایش آبکندهای در شهرستان الشتر با استفاده از مدل‌های هوش مصنوعی است.

مواد و روش‌ها

^۴ Topographic location index (TPI)

^۵ Digital Elevation Model Model (DEM)


^۱ Boosted Regression Tree (BRT)

^۲ Vegetation index (NDVI)

^۳ Topographic humidity index (TWI)

(TPI) با استفاده از نقشه مدل رقومی ارتفاع در نرم افزار SAGA تهیه شد.

در محیط نرم افزار ArcMap نقشه بارش منطقه تهیه شد. شاخص های TWI و شاخص موقعیت توپوگرافی



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه روی نقشه استان لرستان و ایران
Fig. 1. Geographical location of the study area on the map of Lorestan Province and Iran

آبکند (۸۹ آبکند و ۶۲ غیر آبکند)، ۷۰ درصد به عنوان داده های آموزش و ۳۰ درصد برای مرحله اعتبارسنجی استفاده شد. شکل ۲ نمودار جرایمی مراحل مختلف تحقیق را نشان می دهد. در ادامه توضیح مختصری در مورد مدل های استفاده شده در این تحقیق آورده شده است.

مدل حداکثر آنتروپی: مدل (MaxEnt) یک مدل مبتنی بر یادگیری ماشین و هوش مصنوعی است که بر اساس اصل حداکثر سازی آنتروپی عمل می کند (Woodbury et al., 1995). این مدل به طور گسترده در مطالعات مرتبط با تحلیل محیطی و مدل سازی زیستگاه های بوم شناختی استفاده شده است (Peterson et al., 2007; Warren et al., 2011; Moreno et al., 2011).

مدل شبکه عصبی مصنوعی: شبکه عصبی مصنوعی روشی است که دانش ارتباط بین چند مجموعه داده را


پهنه بندی حساسیت به وقوع فرسایش خندقی:

برای پهنه بندی حساسیت به وقوع فرسایش آبکندی با استفاده از مدل های هوش مصنوعی و تعیین بهترین مدل، از مدل های شبکه عصبی مصنوعی (MLP) حداکثر آنتروپی (MaxEnt)، تحلیل تفکیک کننده انعطاف پذیر (FDA)، استفاده شد.

سپس با توجه به بررسی های انجام شده در زمینه فرسایش آبکندی و شرایط منطقه مورد مطالعه عوامل مؤثر بر ایجاد فرسایش آبکندی شامل شیب، جهت شیب، کاربری اراضی، زمین شناسی، فاصله از جاده، فاصله از آبراهه، فاصله از گسل، شاخص پوشش گیاهی، شاخص موقعیت توپوگرافی و شاخص رطوبت توپوگرافی، بارش به عنوان پارامترهای ورودی و نقاط آبکندی و غیر آبکندی به عنوان پارامترهای خروجی برای مدل سازی و پهنه بندی حساسیت به وقوع آبکند در نظر گرفته شد سپس از مجموع ۱۵۱ نقطه وقوع و عدم وقوع

مدل تحلیل تفکیک‌کننده انعطاف‌پذیر (FDA): روش تحلیل تفکیک‌کننده انعطاف‌پذیر (FDA) به‌عنوان یک مدل یادگیری ماشین از نوع طبقه‌بندی متشکل از چندین مدل رگرسیون خطی است. از قابلیت‌های مدل FDA می‌توان به مدل‌سازی تعداد زیادی از متغیرهای مستقل، امکان بررسی و تشخیص خودکار روابط غیرخطی بین عوامل مستقل، دارا بودن الگوریتم محاسباتی بسیار سریع و کارآمد و ایمن بودن نسبت به داده‌های پرت اشاره نمود (Rahmati et al., 1403; Hastie et al., 2009; Hallgren et al., 2019).

از طریق آموزش فرا گرفته و برای استفاده ذخیره می‌کند. در حال حاضر، این تکنیک یکی از پرکاربردترین تکنیک‌های طبقه‌بندی غیرپارامتری است و به هیچ فرضی از توزیع عمومی داده‌ها وابسته نیست (Liou et al., 2001; Lu and Weng, 2007). شبکه عصبی مصنوعی (MLP) دارای یک لایه ورودی، حداقل یک لایه پنهان و یک لایه خروجی است. هر لایه توسط نوروها (مانند اعصاب مغز) تشکیل شده است (Dixon et al., 2008; Schuman et al., 2013).



شکل ۲- نمودار جریانی مراحل مختلف تحقیق
Fig. 2. Flowchart of the different stages of the research

که در آن، TP نشان‌دهنده مثبت واقعی، TN منفی واقعی است. تعداد پیکسل‌هایی که به درستی توسط مدل‌ها دسته‌بندی شده‌اند، به عنوان مثبت واقعی TP و منفی واقعی TN شناخته می‌شود، در حالی که تعداد پیکسل‌هایی که به اشتباه توسط مدل‌ها دسته‌بندی شده‌اند (Zhou et al., 2022; Arabameri et al., 2020; Hu et al., 2024; Fu et al., 2024).

نتایج و بحث

این پژوهش با هدف پهنه‌بندی احتمال وقوع فرسایش آب‌کندی با استفاده از مدل‌های هوش مصنوعی در شهرستان الشتر انجام شده است. لایه‌های مورد استفاده برای تعیین مناطق دارای حساسیت فرسایش

معیار ارزیابی کارایی مدل: در این تحقیق به منظور ارزیابی مدل‌ها از منحنی ROC استفاده می‌شود. منحنی ROC یک رویکرد رایج برای تحلیل عملکرد مدل‌ها است و معمولاً برای دقت پیش‌بینی مدل با مقایسه بین مقادیر واقعی و پیش‌بینی شده استفاده می‌شود. سطح زیر منحنی ROC محدوده بین (۰ و ۱) دارد که هرچه این مقدار به یک نزدیک‌تر باشد عملکرد طبقه‌بندی بهتر است و می‌تواند نمونه‌ها را به دقت تفکیک کند و در مقایسه با مدل‌های دیگر دارای کارایی بهتری برای پیش‌بینی در مرحله آموزش و آزمایش مدل است (Swets, 2014; Rahmati et al., 2019).

ROC با استفاده از رابطه (۱) محاسبه می‌شود.

$$AUC = \frac{(\sum TP + \sum TN)}{(P + N)} \quad (1)$$

است و نواحی که با رنگ آبی تیره دیده می‌شود، نواحی است که گیاهان آن مترکم‌تر و سالم‌تر هستند. نتایج نشان داد بارندگی شرایط متغیری داشته و از میزان ۵۰۰-۷۰۰ میلی‌متر احتمال رخداد فرسایش آبکندی افزایش پیدا کرده است. با افزایش بارندگی از ۶۰۰ میلی‌متر به بالا حساسیت فرسایش آبکندی کاهش یافته است به دلیل اینکه در بارندگی‌های بالای ۵۰۰ میلی‌متر می‌توان به افزایش پوشش گیاهی و ایجاد شرایط برای زمین لغزش‌ها اشاره نمود. اهمیت بارندگی و تاثیر آن بر توسعه فرسایش آبکندی در تحقیقات Gornami et al., (2019)؛ Arabameri et al., (2019) مورد تأکید قرار گرفته است.

در رابطه با فاصله از جاده و ایجاد فرسایش آبکندی نتایج نشان داد که با افزایش فاصله از جاده فرسایش آبکندی بیشتر است که با نتایج Emad al-Din et al., (2021) که عنوان کردند آبکندهای زیادی در نزدیک جاده اتفاق افتاده و با افزایش فاصله از جاده این مقدار کاهش یافته است، مطابقت ندارد. فاصله از آبراهه نقش مهمی در رابطه با فرسایش آبکندی ایجاد می‌کند. مطابق نتایج به دست آمده از تحقیق مشخص شد که بیشتر آبکندها در فاصله >300 متر قرار دارند که با نتایج تحقیق (Rahmati et al., 2016, 2017)؛ Arabameri et al., 2019) همخوانی دارد ولی با نتایج تحقیقات (Chenari et al., (2016)، Dii et al., (2014)، Emad al-Din et al., (2021) مطابقت ندارد زیرا آنها بیان داشتند که آبکندهای زیادی در فاصله کمتر از یک متری از آبراهه اتفاق افتاده است و با افزایش فاصله از آبراهه، درصد فراوانی آبکندها کاهش می‌یابد. فرسایش آبکندی وابسته به چندین عامل لیتولوژیکی است، از جمله فاصله از گسل و طول کلی گسل‌ها در منطقه. نتایج نشان داد، فرسایش آبکندی بیشتر در مناطقی با فاصله بیشتر از گسل‌ها رخ داده است که نتایج این تحقیق با Liu et al., (2025) مطابقت دارد.

مطابق نتایج به دست آمده از تحلیل روابط بین طبقه‌های مختلف شیب و آبکندها در منطقه نشان می‌دهد که بیشتر آبکندها در کلاس شیب ۵-۰ قرار گرفتند و بعد از آن طبقه شیب ۱۵-۵. با این حال محدوده شیب >30 دارای هیچ آبکندی نیست که نشان می‌دهد افزایش شیب شاخص قابل اعتمادی برای

آبکندی در شکل ۳ نشان داده شده است. براساس داده‌های مشاهدتی وقوع فرسایش آبکندی در منطقه مورد مطالعه، نتایج جدول ۱ نشان داد که به ترتیب بیشترین و کمترین بارش‌ها در طبقات ۶۰۰-۷۰۰ و ۴۰۰-۵۰۰ میلی‌متر قرار گرفته است. همچنین برای عوامل فاصله از گسل، فاصله از رودخانه و فاصله از جاده مشخص شد که بیشترین حساسیت به وقوع آبکند در منطقه مورد مطالعه در طبقه بیشتر از ۳۰۰ متر قرار دارد. در مورد شیب و جهت شیب مشخص شد که بیشتر آبکندها در طبقه شیب ۵-۰ و ۱۵-۵ و در جهت شمال قرار دارند که نشان‌دهنده بیشترین حساسیت وقوع آبکند نسبت به سایر طبقات است. در مورد کاربری اراضی مشخص شد به ترتیب بیشترین و کمترین مساحت منطقه مورد مطالعه دارای کاربری اراضی کشاورزی دیم و کاربری مسکونی است و از مجموع ۸۹ آبکند در منطقه مورد مطالعه ۸۲ خندق در کاربری کشاورزی دیم مشاهده شد که نشان‌دهنده بیشترین حساسیت کاربری اراضی کشاورزی دیم نسبت به دیگر کاربری‌ها در منطقه مورد مطالعه است.

برای عوامل خاک و سازند زمین‌شناسی مشخص شد، خاک‌های لیتوسل نیمه مرطوب بیشترین حساسیت به وقوع فرسایش آبکندی نسبت به دیگر گروه‌های خاک منطقه را دارند. براساس نتایج جدول ۱ مشخص شد که تعداد ۴۴ آبکند بر روی سازند آبرفت قدیمی قرار دارد که نشان‌دهنده بیشترین حساسیت این سازند نسبت به دیگر سازندهای منطقه مورد مطالعه است و کمترین آبکندها بر روی سازند مارن‌های قرمز و کنگلومرا-سازند آغاچاری است. شکل ۳ (e) TPI منطقه مورد مطالعه را نشان می‌دهد. با توجه به نتایج به دست آمده از این شکل مشخص شد که TPI منطقه مورد مطالعه بین ۵۴/۷۶- تا ۶۶/۳۰ متغیر است. توزیع فضایی شاخص رطوبت توپوگرافی در منطقه مورد مطالعه در شکل ۳ (k) نشان داده شده است. مقدار این شاخص در محدوده بین ۵/۴۹- تا ۶/۹۰ است.

بنابراین مناطقی که دارای شاخص رطوبت توپوگرافی بالا هستند خطر فرسایش بیشتری را دارا هستند. با توجه به شکل ۳ (g) شاخص NDVI منطقه مورد مطالعه بین ۰/۱۴- تا ۰/۵۵ متغیر است. نواحی که با رنگ قهوه‌ای دیده می‌شود نواحی متأثر از خشکسالی

حساسیت زیاد مارن به فرسایش دانست. که با نتایج تحقیق Gornami et al., Mehraban et al., 2018؛ 2019؛ Azareh et al., 2019 همخوانی دارد. افزایش حساسیت فرسایش آبکندی با افزایش شاخص رطوبت توپوگرافی، رابطه مستقیم دارد.

هرچه رطوبت بیشتر باشد آبکندهای بیشتری رخ می‌دهد به عبارت دیگر در مناطقی که رطوبت و میزان سطوح اشباع افزایش می‌یابد، احتمال رخداد و حساسیت فرسایش آبکندی افزایش پیدا می‌کند. شاخص پوشش گیاهی رابطه معکوسی با فرسایش آبکندی دارد، به این صورت که با افزایش پوشش گیاهی احتمال رخداد فرسایش آبکندی کاهش می‌یابد به دلیل اینکه پوشش گیاهی با کاهش قدرت فرساینده‌ی رواناب سطحی و بهم چسباندن ذرات خاک از طریق ریشه، باعث کاهش حساسیت فرسایش آبکندی می‌شود (Conforti et al., 2011).

در بخش مدلسازی و تهیه نقشه حساسیت به وقوع فرسایش آبکندی مشخص شد که از بین مدل‌های مورد استفاده در این تحقیق، مدل شبکه عصبی مصنوعی (MLP) با توجه به معیار ارزیابی کارایی مدل در مرحله آموزش و اعتبارسنجی به ترتیب برابر با ۰/۹۶ و ۰/۹۱ نسبت به دیگر مدل‌های استفاده شده در این تحقیق به عنوان برترین مدل برای پهنه‌بندی حساسیت به وقوع فرسایش آبکندی در منطقه مورد مطالعه تعیین شد.

آبکندها نیست. نتایج این تحقیق با (Liu et al., 2025)، (Madadi et al., 2022) همخوانی دارد اما با نتایج مطالعه (Abedini 2005)، (Yamani et al., 2013)، شیب ۳-۰ درصد، (Servati et al., 2008)، شیب ۱۰-۰، (Nohegar et al., 2011)، شیب ۶-۰ درصد را مؤثرترین درصد شیب بر وقوع فرسایش آبکندی در منطقه مطالعاتی خویش معرفی کردند مطابقت ندارد. رابطه بین جهت شیب و فرسایش آبکندی نشان داد که آبکندها بیشتر در جهت‌های شمال، شمال شرقی و شرق تشکیل شده‌اند که با نتایج (Madadi et al., 2022) مطابقت دارد ولی با نتایج (Liu et al., 2025)، (Arab Qashqai et al., 2011)، زیرا آن‌ها بیان نمودند که جهت جنوب و جنوب شرقی بیشترین درصد آبکند را دارد که دلیل این امر را آفتاب‌گیر بودن این جهت‌های جغرافیایی نسبت به جهت‌های دیگر دانسته‌اند.

با ترکیب نقشه کاربری اراضی منطقه الشتر با نقشه مناطق تحت تأثیر فرسایش آبکندی مشخص گردید که بیشترین میزان آبکندها در کاربری کشاورزی خشک قرار گرفته است که با نتایج (Madadi et al., 2022)، (Yamani et al., 2013)، (Chenari et al., 2016) مطابقت داشت. از بین سازندهای موجود در منطقه فرسایش آبکندی بیشتر بر روی سازندهای، آبرفت قدیمی، آهک مارنی آبی رنگ، آهک مارنی، آهک مارنی بسن سانتیونین وجود داشت. که دلیل آن را می‌توان


جدول ۱- مقادیر حاصل از ارتباط بین عوامل مؤثر بر وقوع فرسایش آبکندی در منطقه مورد مطالعه

Table 1. Values resulting from the relationship between factors affecting gully erosion occurrence in the study area

Frequency ratio	Percentage of non-gully pixels	Percentage of gully pixels	Number of non-gully pixels	Number of gully pixels	Total area (ha)	Class	Parameter
0	20.14	0	2500	0	29305	400-500	Precipitation
1.63	19.90	32.58	2471	29	27742	500-600	
2.62	19.82	44.94	2460	40	33823	600-700	
0.95	20	19.10	2483	17	32050	700-800	
0.16	20.11	3.37	2497	3	28545	800-900	
0	2.35	0	14322.67	0	3580	0-100	Distance from fault
0	2.41	0	14703.48	0	3675	100-200	
0	2.46	0	15017.57	0	3754	200-300	
1.07	92.76	100	564811.19	89	141225	>300	Distance from river
1.60	7.68	12.35	46845.36	11	11714	0-100	
2.07	7.59	15.73	46292.64	14	11576	100-200	
0.90	7.45	6.74	45446.66	6	11363	200-300	
0.84	77.25	65.16	470744.03	58	117700	>300	
1.45	3.09	4.49	18879.81	4	4720.95	0-100	Distance from road
0	3.07	0	18744.93	0	4686.23	100-200	
۰/۷۴	3.02	2.24	18433.20	2	4609.05	200-300	
۱/۰۲	90.79	93.25	553269.75	83	138338	>300	Slope
1.59	49.35	78.6	298984	70	74763	0-5	
0.70	28.61	20.2	173320	18	43334	5-15	


Frequency ratio	Percentage of non-gully pixels	Percentage of gully pixels	Number of non-gully pixels	Number of gully pixels	Total area (ha)	Class	Parameter
0.07	15.18	1.12	92012	1	23003	15-30	Aspect
0	6.84	0	41462	0	10365	>30	
0.41	8.14	3.37	49365	3	12342	Plain	
2.05	26.74	55	161990	49	40509	North	
1/14	19.62	22.47	118905	20	29731	Northeast	
1.01	14.32	14.60	86796	13	21702	East	
0.42	10.68	4.49	64749	4	16188	Southeast	
0	7.73	0	46847	0	11711	South	
0	6.11	0	37044	0	9261	Southwest	
0	3.82	0	23172	0	5793	West	
0	2.79	0	16910	0	4227	Northwest	
0.32	10.06	3.3	61352	3	15338	Irrigated agriculture	
0	0.067	0	409	0	102.25	Garden	
0	1.39	0	8511	0	2127	Dense forest	
0	7.20	0	43910	0	10977	Good rangeland	
0.052	21.39	1.12	130345	1	32586	Sparse forest	Land use
3.40	27.09	92.13	165080	82	41290	Rainfed agriculture	
0	13.77	0	83925	0	20981	Medium-density forest	
0.21	15.67	3.3	95501	3	23876	Medium rangeland	
0	3.07	0	18711	0	4677	Poor rangeland	
0	0.25	0	1583	0	395.75	Residential	Soil
1.22	66.69	82	406393	73	101616	Semi-moist Lithosols	
0.87	17.98	15.7	109565	14	27394	Brown Steppe Soils	
0.14	15.32	2.24	93385	2	23346	Non-saline Alluvial Soils	
0	0.44	0	2701	0	675	(Bgp)	
0	3.72	0	22715	0	5678	Massive white limestone. Bakhtyari	
0	1.71	0	10434	0	2608	Conglomerate, Conglomerate with red cherts	
0	3.38	0	20599	0	5149	(Bk)	
0	0.28	0	1761	0	440	(Gu)	
0	15.33	0	93455	0	23363	Radiolarite-bearing section, Radiolarite complex. Dolomitic limestone	
0	3.44	0	20999	0	5249	(Maastrichtian - Cenomanian), Limestone, Limestone and Shale	
0	5.53	0	33723	0	8430	Orbitolina-bearing limestone Blue Marl Limestone, Marl	
3.63	11.14	40.44	67931	36	16991	Limestone, Marl Limestone (Santonian) Shale, Sandstone, Conglomerate	Geology1
0	6.52	0	39746	0	9936	– Amiran Formation, (Kgp)	
0	0.64	0	3908	0	977	Red Marls and Conglomerate	
18.05	0.56	10.11	3414	9	855	– Aghajari	

Frequency ratio	Percentage of non-gully pixels	Percentage of gully pixels	Number of non-gully pixels	Number of gully pixels	Total area (ha)	Class	Parameter
0	17	0	103627	0	25906	Formation, Razak	
0	5.07	0	30933	0	7733	Formation MI Coral	
0	0.87	0	5344	0	1336	Limestone, Oolitic Limestone Conglomerate with elements from local outcrops.	
2.07	23.79	49.43	144968	44	36253	Old Alluvium	
0	0.01	0	120	0	30	Middle Dolomite Member	
0	0.006	0	41	0	10	Volcanic, Laterite	
0	0.47	0	2868	0	717	Tarbur Formation	



شکل ۳- نقشه داده‌های ورودی مدل‌سازی حساسیت به وقوع فرسایش آب‌بندی، الف: کاربری اراضی، ب: خاک، پ: فاصله از جاده، ت: شیب، ث: شاخص موقعیت توپوگرافی TPI، ج: جهت شیب، چ: شاخص پوشش گیاهی NDVI، ح: فاصله از گسل، خ: بارش، د: سازند زمین‌شناسی، ذ: شاخص رطوبت توپوگرافی TWI، ر: فاصله از آبراهه


Fig. 3. Input data maps for modeling susceptibility to gully erosion occurrence: (a) Land use, (b) Soil, (c) Distance from road, (d) Slope, (e) Topographic Position Index (TPI), (f) Slope aspect, (g) Normalized Difference Vegetation Index (NDVI), (h) Distance from fault, (i) Precipitation, (j) Geological formation, (k) Topographic Wetness Index (TWI), (l) Distance from stream



ادامه شکل ۳
Fig. 3. Continued

(FDA) به ترتیب در مرحله آموزش برابر ۹۶ و ۹۶ درصد و در مرحله آزمایش، به ترتیب برابر ۹۱/۵ و ۸۶ درصد بوده است. مطابق نتایج جدول ۲ مشخص گردید که مدل شبکه عصبی مصنوعی (MLP) با توجه به معیار ارزیابی دقت مدل AUC به عنوان مدل برتر برای پهنه بندی حساسیت به وقوع فرسایش آبکندی در منطقه مورد مطالعه انتخاب شد. همچنین با توجه به نتایج این جدول مدل تحلیل تفکیک کننده انعطاف پذیر (FDA) با توجه به معیار ارزیابی دقت به عنوان بدترین مدل برای پهنه بندی حساسیت به وقوع فرسایش آبکندی در شهرستان الشتر انتخاب شد.

شکل ۴ ارزیابی نتایج مدل سازی تهیه نقشه پهنه بندی فرسایش آبکندی با استفاده از مدل های MLP، MaxEnt و FDA را نشان می دهد. همچنین نتایج بررسی عملکرد مدل های مورد استفاده برای تهیه پهنه بندی حساسیت به وقوع فرسایش آبکندی در جدول ۲ آورده شده است که مطابق نتایج این جدول، به ترتیب در هر دو مرحله آموزش و آزمایش میزان AUC برای مدل شبکه عصبی مصنوعی (MLP)، به ترتیب برابر ۹۸ و ۹۲ درصد بوده است. علاوه بر این میزان AUC برای نتایج مدل های حداکثر آنتروپی (MaxEnt) و تحلیل تفکیک کننده انعطاف پذیر



شکل ۴- نتایج مقادیر ROC در بخش آموزش و اعتبارسنجی مدل، A: FDA; B: MLP; C: MaxEnt.

Fig. 4. ROC values in the training and validation sections of the model: A: FDA; B: ALP; C: MaxEnt


نشان می دهد. بر اساس نتایج شکل ۵ و جدول ۳ مشخص شد که در همه مدل ها طبقه با حساسیت خیلی کم، بیشترین مساحت را به خود اختصاص داده است.

شکل ۵ نقشه پهنه بندی حساسیت فرسایش آبکندی در منطقه مورد مطالعه با استفاده از مدل های شبکه عصبی مصنوعی (MLP)، حداکثر آنتروپی (MaxEnt)، تحلیل تفکیک کننده انعطاف پذیر (FDA) را

جدول ۲- نتایج بررسی عملکرد مدل‌های مورد استفاده برای پهنه‌بندی حساسیت به وقوع فرسایش آبکند

Table 2. The results of the performance evaluation of the models used for gully erosion susceptibility mapping.

TEST	Training	Models
0.92	0.98	Artificial Neural Network (MLP)
0.915	0.96	Maximum Entropy (MaxEnt)
0.86	0.96	Flexible Discriminant Analysis(FDA)



شکل ۵- نقشه پهنه‌بندی حساسیت فرسایش آبکندی در منطقه مورد مطالعه با استفاده از مدل‌های A: حداکثر آنتروپی (MaxEnt)؛ B: شبکه عصبی مصنوعی (ALP)؛ C: تحلیل تفکیک‌کننده انعطاف‌پذیر (FDA)

Fig. 5. Mapping map of gully erosion susceptibility in the study area using the models of: A) Maximum Entropy (MaxEnt); B) Artificial Neural Network (MLP); C) Flexible Discriminant Analysis (FDA)

با ۷۷/۸۲ درصد بیشترین مساحت منطقه مورد مطالعه را به خود اختصاص داده است. نتایج مدل تحلیل تفکیک‌کننده انعطاف‌پذیر (FDA) نشان داد که در منطقه مورد مطالعه ۳۲/۴۶ درصد در طبقه خطر خیلی کم، ۱۰/۶۲ درصد در طبقه خطر کم، ۱۰/۱۷ درصد در طبقه خطر متوسط، ۱۳/۳ درصد در طبقه خطر زیاد و ۳۳/۴۳ درصد در طبقه خطر خیلی زیاد قرار گرفته است.

جدول ۳ درصد مساحت هر یک از طبقات حساسیت فرسایش آبکندی برای نتایج مدل‌های مختلف را نشان می‌دهد که براساس این جدول، مشخص گردید در مدل شبکه عصبی مصنوعی به ترتیب بیشترین و کمترین درصد مساحت با ۲۴/۶۵ و ۱۰/۰۵ در طبقه خطر خیلی کم و خیلی زیاد قرار دارد، همچنین با توجه به نتایج بدست آمده از مدل حداکثر آنتروپی (MaxEnt)، مشخص شد که طبقه حساسیت خیلی کم

جدول ۳- مساحت و درصد مساحت طبقات حساسیت فرسایش آبکندی با استفاده از مدل‌های شبکه عصبی مصنوعی (ALP)، حداکثر آنترپی (MaxEnt)، تحلیل

تفکیک‌کننده انعطاف‌پذیر (FDA) در منطقه مورد مطالعه

Table 3. Area and percentage area of gully erosion susceptibility classes using Artificial Neural Network (MLP), Maximum Entropy (MaxEnt), and Flexible Discriminant Analysis (FDA) models in the study area

Susceptibility class	Percentage of area	Models
Very low	24.65	MLP
Low	22.82	
Medium	21.28	
High	21.17	
Very high	10.05	
Very low	77.82	MaxEnt
Low	12.72	
Medium	5.24	
High	2.70	
Very high	1.50	
Very low	32.46	FDA
Low	10.62	
Medium	10.17	
High	13.3	
Very high	33.43	

نتیجه‌گیری

فرسایش آبکندی یکی از مخرب‌ترین شکل‌های فرسایش خاک است که در نتیجه تعامل پیچیده چندین عامل محیطی توسعه می‌یابد. یافته‌های علمی نشان داد که وقوع و تشدید این پدیده عمدتاً تحت سلطه چهار متغیر کلیدی اقلیم، سنگ‌شناسی، ویژگی‌های خاک و الگوی بارش است. این عوامل در یک چارچوب سیستماتیک، هم به عنوان بستر اولیه و هم به عنوان محرک‌های پویا عمل می‌کنند. سنگ‌شناسی نقش عامل کنترل‌کننده اصلی را ایفا می‌کند. سازندهای سست و با مقاومت پایین مانند مارن‌ها، رسوبات رسی و سیلتی به دلیل ضعف پیوند بین ذرات، مستعد جدا شدن و انتقال توسط جریان آب هستند. این لایه‌های حساس، بستر فیزیکی اولیه برای آغاز فرسایش خطی را فراهم می‌کنند. همچنین، نفوذپذیری کم برخی از این سازندها موجب افزایش تولید رواناب سطحی می‌شود.

ویژگی‌های خاک به عنوان لایه پوشاننده سنگ بستر، دومین عامل کنترل‌کننده حیاتی است. خاک‌هایی با بافت ریز، ساختمان ضعیف و پایداری کم خاکدانه‌ها (مانند بسیاری از خاک‌های رسی) در برابر نیروهای برشی آب آسیب‌پذیرند. هنگامی که این خاک‌ها اشباع می‌شوند، انسجام خود را از دست داده و به سرعت فرسایش می‌یابند. اقلیم‌های نیمه‌خشک و مدیترانه‌ای به دلیل ترکیب ویژگی‌هایی مانند بارش‌های متمرکز، پوشش گیاهی تنک و دوره‌های خشکی طولانی، مناسب‌ترین بستر برای توسعه آبکندها هستند.

در این اقلیم‌ها، پوشش گیاهی ضعیف قادر به محافظت مؤثر از خاک و کاهش انرژی قطرات باران نیست در نتیجه، می‌توان بیان داشت که مهم‌ترین عامل مؤثر یک متغیر منفرد نیست، بلکه ترکیب خطرناک بارش‌های با شدت بالا بر روی سازندهای سست و خاک‌های حساس به فرسایش است. این تقابل، شرط لازم و کافی برای شکل‌گیری سریع و پیشرونده آبکندها را فراهم می‌سازد. همچنین نتایج نشان داد که در مرحله آزمایش، مدل شبکه عصبی مصنوعی (MLP) بهترین عملکرد را با توجه به معیار ارزیابی مدل ($AUC=0.92$) کسب کرده است و پس از آن به ترتیب مدل‌های MaxEnt ($AUC=0.915$) و FDA ($AUC=0.86$) قرار دارند. دقت خوب به دست آمده از مدل‌ها به دلیل این است که هر نوع فرسایش مجموعه‌ای از عوامل مؤثر به خود را دارد که باید به طور جداگانه ارزیابی شوند. بنابراین، نتایج به دست آمده از این پژوهش، دیدگاه مناسبی را در مورد تأثیر عوامل مؤثر در ایجاد فرسایش آبکندی در اختیار برنامه‌ریزان و محققان قرار می‌دهد. این پژوهش بر این نکته تأکید دارد که به کارگیری فناوری‌های نوین هوش مصنوعی، می‌تواند چارچوبی علمی، کم‌هزینه و کارآمد برای مدیریت پایدار اراضی فراهم آورد.

پیشنهاد می‌شود از نقشه‌های حاصل از این پژوهش در برنامه‌ریزی‌های محلی، اجرای طرح‌های حفاظتی استفاده شود. در مجموع، این مطالعه نشان می‌دهد که رویکرد مبتنی بر هوش مصنوعی نه تنها جایگزینی

بدین وسیله نویسندگان مراتب قدردانی و تشکر خود را از تمامی کارشناسان و دانشگاه لرستان جهت همکاری در انجام این پژوهش اعلام می‌دارند.

کارآمد برای روش‌های سنتی پهنه‌بندی است، بلکه با آشکارسازی تعامل پیچیده عوامل طبیعی و انسانی، درک جامع‌تری از فرسایش آبکندی ارائه می‌دهد و راه را برای مدیریت پیش‌گیرانه و هوشمند این چالش محیط‌زیستی هموار می‌سازد.

تعارض منافع

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

تشکر و قدردانی

منابع مورد استفاده

- Abedini, M. 2005. A Study on Gully Erosion of the Highlands in Southwest of Hadishahr Plain, Northwest of East Azerbaijan through New Methods and Techniques. *Geography and Development Journal*, 3(6), 113-134 (in Persian).
- Ahmadpour, H., Bazrafshan, O., Rafiei-Sardooi, E., Zamani, H., Panagopoulos, T., 2021. Gully erosion susceptibility assessment in the Kondoran watershed using machine. 2-23.
- Arabameri, A., Blaschke, T., Pradhan, B., Pourghasemi, H.R., Tiefenbacher, J.P., Bui, D.T., 2020c. Evaluation of recent advanced soft computing techniques for gully erosion susceptibility mapping: A comparative study. *Sensors* 20 (2), 335.
- Arabameri, A., Chen, W., Loche, M., Zhao, X., Li, Y., Lombardo, L., Cerda, A., Pradhan, B., Bui, D.T., 2020a. Comparison of machine learning models for gully erosion susceptibility mapping. *Geoscience Frontiers*. 11 (5), 1609–1620.
- Arabameri, A., Pradhan, B., Rezaei, K., Conoscenti, C., 2019. Gully erosion susceptibility mapping using GIS-based multi-criteria decision analysis techniques. *Catena* 180, 282–297. <https://doi.org/10.1016/j.catena.2019.04.032>.
- Asadi Nalivan, O., Rabet, A., Vakili Tajareh, F., Ramezani, M., Momeni, M., Heidari, K., 2023. Zoning of gully erosion susceptibility using Ann, CART, and RF models, *Watershed Engineering and Management*, 15(2): 155-171 (in Persian).
- Azareh, A., O. Rahmati, E. Rafiei, J. Sankey, S. Lee, H. Shahabi and B. Ahmad. 2019. Modelling gully erosion susceptibility in a semi-arid region, Iran: investigation of applicability of certainty factor and maximum entropy models. *Science of the Total Environment*, 655: 684–696.
- Borrelli, P., Robinson, D.A., Panagos, P., Lugato, E., Yang, J.E., Alewell, C., Wuepper, D., Montanarella, L., Ballabio, C., 2020. Land use and climate change impacts on global soil erosion by water (2015-2070). *Proceedings of the National Academy of Sciences of the United States America*. 117 (36), 21994–22001.
- Breiman, L., 2001. Random forests. *Mach. Learn.* 45 (1), 5–32.
- Chen, W., Lei, X., Chakraborty, R., Pal, S.C., Sahana, M., Janizadeh, S., 2021. Evaluation of different boosting ensemble machine learning models and novel deep learning and boosting framework for head-cut gully erosion susceptibility. *Journal of Environmental Management*. 284. 112015.
- Chenari K, Bahremand A, Bordi Sh, Komaki Ch, 2016. Zoning the Risk of Erosion Occurrence Potential Using Statistical Methods in the Gernaveh Watershed, Golestan Province, *Ecohydrology Journal*, 3(2): 219-231 (in Persian).
- Chowdhuri, I., Pal, S.C., Saha, A., Chakraborty, R., Roy, P., 2021. Evaluation of different DEMs for gully erosion susceptibility mapping using in-situ field measurement and validation. *Ecological Informatics*. 65. 101425.
- Chuma, G., Mugumaarhahama, Y., Mond, J., Bagula. E., Ndeko, A., Lucungu, P., Karume, K., Mushagalusa, G., Schmitz, S., 2023. Gully erosion susceptibility mapping using four machine learning methods in Luzinzi watershed, eastern Democratic Republic of Congo. *Physics and Chemistry of the Earth* 129 (2023) 103295.
- Conforti, M., Aucelli, P.P.C., Robustelli, G. and Scarciglia, F. 2011. Geomorphology and GIS analysis for mapping gully erosion susceptibility in the Turbolo stream catchment (Northern Calabria, Italy). *Natural Hazards*, 56, 881–898.
- Dixon, B., Candade, N., 2008. Multispectral land use classification using neural networks and support vector machines: one or the other, or both? *International Journal of Remote Sensing*. 29 (4), 1185–1206.
- Domazetovic, F., Siljeg, A., Loncar, N., Maric, I., 2019. Development of automated multicriteria GIS analysis of gully erosion susceptibility. *Appl. Geogr.* 2019.102083. 112 102083. <https://doi.org/10.1016/j.apgeog.2019.102083>.

- Davoudi, A., Karam, A., Zeaiean Firouzabadi, P., Ahmadabadi, A., 2025. Assessment of gully erosionprone areas in the Aleshtar basin using machine learning models. *Natural Disasters*, 1 (1), 63-82.
- Emadodin, S., Omid, M., Arkhi, S., & Karam, A. 2021. Risk assessment of gully erosion occurrence in Ghoojagh watershed. *Scientific-Research Journal of Natural Environmental Hazards*, 10 (4, Serial No. 30), 17-34 (in Persian).
- Fu, L., Guo, J., Shen, W., Wang, X., et al., 2024. Geophysical Evidence of the Collisional Suture Zone in the Prydz Bay, East Antarctica. *Geophysical Research Letters* 51 (2). <https://doi.org/10.1029/2023GL106229>.
- Gao, R., Gao, M., Yao, Sh., Wen, Y., 2025. Gully erosion susceptibility mapping considering seasonal variations of NDVI using a machine learning approach in the Mollisol region of China. *Soil & Tillage Research* 245 (2025) 106322.
- Garosi, Y., Sheklabadi, M., Pourghasemi, H.R., Besalatpour, A.A., Conoscenti, C., Van Oost, K., 2018. Comparison of differences in resolution and sources of controlling factors for gully erosion susceptibility mapping. *Geoderma* 330, 65–78. <https://doi.org/10.1016/j.geoderma.2018.05.027>.
- Garosi, Y., Sheklabadi, M., Pourghasemi, H.R., Besalatpour, A.A., Conoscenti, C., Van Oost, K., 2018. Comparison of differences in resolution and sources of controlling factors for gully erosion susceptibility mapping. *Geoderma* 330, 65–78.
- Gornami, R. and S. Shadfar. 2019. Application of the GIS in the determination of susceptible areas to gully erosion using the ANP. *Watershed Management Research*, 31(4): 58-68 (in Persian).
- Gornami, R. and S. Shadfar. 2019. Application of the GIS in the determination of susceptible areas to gully erosion using the ANP. *Watershed Management Research*, 31(4): 58-68 (in Persian).
- Hallgren, W., Santana, F., Low-Choy, S., Zhao, Y., & Mackey, B. 2019: Species distribution models can be highly sensitive to algorithm configuration. *Ecological Modelling*, 408, 108719.
- Hasanuzzaman, M., Adhikary, P., Shit, P., 2024. Gully erosion susceptibility mapping and prioritization of gully-dominant sub-watersheds using machine learning algorithms: Evidence from the Silabati River (tropical river, India). *Advances in Space Research* 73 (2024) 1653–1666.
- Hastie, T., Tibshirani, R., Friedman, J.H., & Friedman, J.H. 2009: The elements of statistical learning: data mining, inference, and prediction. 2, 1-758. doi:10.1007/978-0-387-21606-5.
- Hitouri, S., Meriam, M., Ajim, A., Pacheco, Q., Nguyen-Huy, T., Bao, P., ElKhrachy, I., Varasano, A., 2024. Gully erosion mapping susceptibility in a Mediterranean environment: A hybrid decision-making model. *International Soil and Water Conservation Research*. 12(2), 279-297. doi: 10.1016/j.iswcr.2023.09.008.
- Hu, M., Niu, Q., Yuan, W., Wang, W., et al., 2024. Evolution characteristic and mechanism of microstructure, hydraulic and mechanical behaviors of sandstone treated by acid-rock reaction: Application of in-situ leaching of uranium deposits. *Journal of Hydrology* 643. 131948. <https://doi.org/10.1016/j.jhydrol.2024.131948>.
- Igwe, O., John, U.I., Solomon, O., Obinna, O., 2020. GIS-based gully erosion susceptibility modeling, adapting bivariate statistical method and AHP approach in Gombe town and environs Northeast Nigeria. *Geoenvironmental Disasters* 7, 1–16.
- Khazaei M., Shirani K., Saleh A., 2024. Investigation of Factors Affecting Gully Erosion and Preparation of Zoning Map in Takht-e Deraz Watershed. *Environmental Erosion Research*, 3(14), 123-141(in Persian).
- Kheir, R.B., Wilson, J., Deng, Y., 2007. Use of terrain variables for mapping gully erosion susceptibility in Lebanon. *Earth Surface Processes and Landforms: the Journal of the British Geomorphological Research Group* 32 (12), 1770–1782.
- Kuhnert, P.M., Henderson, A.-K., Bartley, R., Herr, A., 2010. Incorporating uncertainty in gully erosion calculations using the random forests modelling approach. *Environmetrics* 21, 493–509. <https://doi.org/10.1002/env.999>.
- Lei, X., Chen, W., Avand, M., Janizadeh, S., Kariminejad, N., Shahabi, H., Costache, R., Shahabi, H., Shirzadi, A., Mosavi, A., 2020. GIS based machine learning algorithms for gully erosion susceptibility mapping in a semi-arid region of Iran. *Remote Sensing*. 12 (15), 2478.
- Liou, Y.-A., Liu, S.-F., Wang, W.J., 2001. Retrieving soil moisture from simulated brightness temperatures by a neural network. *IEEE Transactions on Geoscience and Remote Sensing*. 39, 1662–1673.
- Liu, J., Araba meri, A., Surabh i Das, CH., Sarkar, P., 2025. An integrated approach for gully erosion susceptibility mapping and factor effect analysis. *Advances in Space Research* 75 (2025) 3451–3470.
- Lombardo, L., Cama, M., Conoscenti, C., M`arker, M., Rotigliano, E.J., 2015. Binary logistic regression versus stochastic gradient boosted decision trees in assessing landslide susceptibility for multiple-occurring landslide events: application to the 2009 storm event in Messina (Sicily, southern Italy). *Natural Hazards* 79 (3), 1621–1648. <https://doi.org/10.1007/s11069-015-1915-3>.

- Lu, D., Weng, Q.A., 2007. Survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*. 28 (5), 823–870.
- Madadi A., Saraskanroud P., Marhamat M., 2022. The Role of Soil Characteristics and Topographic Threshold in Gully Erosion in the Shour River Watershed (Mohr County). *Quantitative Geomorphological Research*, 10(4): 75-95 (in Persian).
- Mehraban, M., Golkarian, A. and Khosravi, K. 2018. Evaluation of susceptibility to gully erosion using maximum entropy model)Case study: Shorlouq region of Khorasan Razavi province). Third National Conference on Soil Conservation and Watershed Management, Soil Conservation and Watershed Management Institute, Tehran, Iran.
- Moreno, R., Zamora, R., Molina, J.R., Vasquez, A., Herrera, M.A., 2011. Predictive modeling of microhabitats for endemic birds in South Chilean temperate forests using Maximum entropy (Maxent). *Ecological Informatics*. 6 (6), 364–370. <https://doi.org/10.1016/j.ecoinf.2011.07.003>.
- Nohegar, A and Heidarzadeh, M. 2011. Study of Physico-Chemical Characteristics and Morphometry of Trench Areas Case Study, Gozir, Hormozgan Province, *Erosion Research Environmental*, No1. (In Persian).
- Poesen, J., 2011. Challenges in gully erosion research. *Landform Analysis* 17, 5–9.
- Poesen, J., Nachtergaele, J., Verstraeten, G., Valentin, C., 2003. Gully erosion and environmental change: importance and research needs. *Catena* 50 (2–4), 91–133.
- Poesen, J., Vandaele, K., van Wesemael, B., 1998. Gully erosion: importance and model implications. In: *Modelling Soil Erosion by Water*. Springer, Berlin, Heidelberg, pp. 285–311.
- Qashqaei, A., Nik-Kami, D., Shadfar, S., & Moeini, A. 2011. Zoning of gully erosion in the Taroud Firuzkuh watershed. *Geographical Territory Quarterly Journal*, 8 (31), 107-119 (in Persian).
- Rahmati A., Karnejadi A., Chobin B., Jafari A., Amini A., 2024. Evaluation of the Capability of the Flexible Discriminant Analysis Model in Predicting Flood Susceptibility of the Zarrineh River Watershed. *Water and Soil Management Modeling*, 4(3): 269-284 (in Persian).
- Rahmati o., Kornejady A., Samadi M., C. Deo R., Conoscenti C., Lombardo L., Dayal K., Taghizadeh-Mehrjardi R., Pourghasemi H., Kumar S., Tien Bui D. 2019: PMT: New analytical framework for automated evaluation of geo-environmental modelling approaches. *Science of the Total Environment* 664 (2019) 296–311.
- Rahmati, O., Tahmasebipour, N., Haghizadeh, A., Pourghasemi, H.R., Feizizadeh, B., 2017. Evaluation of different machine learning models for predicting and mapping the susceptibility of gully erosion. *Geomorphology* 298, 118–137.
- Saeidian H., Shirani K., Salajegheh A., Ahmadi R.; 2023. Performance of the Maximum Entropy Model in Determining the Importance of Environmental Factors in Gully Erosion Initiation in Semi-Arid Regions. *Journal of Novel Approaches in Water Engineering and Environment*, 2 (1): 129-144 (in Persian).
- Schuman, C.D., Birdwell, J.D., 2013. Dynamic artificial neural networks with affective systems. *PLoS One* 8, e80455.
- Servati, M.R. Qudusi, J. Dadkhah, M. 2008. Factors affecting formation and spread of gully erosion in loesses, 21(1): 20 - 33. (In Persian).
- Shahbazi,k., Vakili Tajareh, f., 2021. Prioritization of Factors Affecting Gully Erosion and Determination of Sensitive Areas in Kermanshah Province Using the MaxEnt Model, *Iranian Journal of Watershed Management Science and Engineering*, 15(54): 48-58 (in Persian).
- Soleimanpour, S.M., Pourghasemi, H.R., Zare, M., 2021. A comparative assessment of gully erosion spatial predictive modeling using statistical and machine learning models. *Catena* 207 105679. <https://doi.org/10.1016/j.catena.2021.105679>.
- Swets, J.A., 2014: *Signal Detection Theory and ROC Analysis in Psychology and Diagnostics: Collected Papers*. Psychology Press.
- Tajvosi M., Fathollahzadeh T., 2003. A Study of Erosion Types in the Masuleh River Watershed (Gilan Province), *Journal of Natural Resources of Iran*, 56(3(Serial 1430)): 15-164(in Persian).
- Therneau, T.M., Atkinson, B., Ripley, B., 2014. Recursive Partitioning and Regression Trees. R package version. <http://CRAN.R-project.org/package=rpart>.
- Tien Bui, D., Shirzadi, A., Shahabi, H., Chapi, K., Omidvar, E., Thai Pham, B., Talebpour, D., Khaledian, H., Pradhan, B., Panahi, M., Ahmad, B., Rahmani, H, Grof, G. and Lee, S. 2019. A Novel Ensemble Artificial Intelligence Approach for Gully Erosion Mapping in a Semi-Arid Watershed (Iran). *Sensors*, 19, 2444.
- Townsend Peterson, A., Papes, M., Eaton, M., 2007. Transferability and model evaluation in ecological niche modeling: a comparison of GARP and Maxent. *Ecography* 30, 550–560. <https://doi.org/10.1111/j.0906-7590.2007.05102.x>.

- Townsend Peterson, A., Papes, M., Eaton, M., 2007. Transferability and model evaluation in ecological niche modeling: a comparison of GARP and Maxent. *Ecography* 30, 550–560. <https://doi.org/10.1111/j.0906-7590.2007.05102.x>.
- Valentin, C., Poesen, J., Li, Y., 2005. Gully erosion: impacts, factors and control. *Catena* 63 (2–3), 132–153.
- Wang, F., Sahana, M., Pahlevanzadeh, B., Pal, S. C., Shit, P. K., Piran, M. J., Mosavi, A., 2021. Applying different resampling strategies in machine learning models to predict head cut gully erosion susceptibility. *Alexandria Engineering Journal*, 60(6), 5813–5829. <https://doi.org/10.1016/j.aej.2021.04.026>.
- Wang, Q., Tang, B., Wang, K., Shi, J., Li, M., 2024. Evaluation of the gully erosion susceptibility by using UAV and hybrid models based on machine learning. *Soil and Tillage Research*. 224 (2), 106218.
- Warren, D.L., Seifert, S.N., 2011. Ecological niche modeling in Maxent: the importance of model complexity and the performance of model selection criteria. *Ecological Applications*. 21(2), 335–342. <https://doi.org/10.1890/10-1171.1>.
- Woodbury, A.D., Render, F.W., Ulrych, T.J., 1995. Practical probabilistic groundwater modeling. *Groundwater* 33 (4), 532–538.
- Yamani, S., M. Zamanzadeh and M. Ahmadi. 2013. Analysis of factors affecting the formation and development of gully erosion: a case study of Kahoor Plain in Fars Province. *Geographical Exploration Desert*, 1: 53–84 (in Persian).
- Zabihi, M., Mirchooli, F., Motevalli, A., Darvishan, A.K., Pourghasemi, H.R., Zakeri, M.A., Sadighi, F., 2018. Spatial modelling of gully erosion in Mazandaran Province, northern Iran. *Catena* 161, 1–13.
- Zhou, G., Li, H., Song, R., Wang, Q., et al., 2022. Orthorectification of Fisheye Image under Equidistant Projection Model. *Remote Sensing* 14 (17), 4175. <https://doi.org/10.3390/rs14174175>.
- Zhou, G., Tang, Y., Zhang, W., Liu, W., Jiang, Y., Gao, E. Bai, Y., 2023. Shadow Detection on High-Resolution Digital Orthophoto Map Using Semantic Matching. *IEEE Transactions on Geoscience and Remote Sensing*, 61. <https://doi.org/10.1109/TGRS.2023.3294531>.
- Zhou, G., Zhou, X., Chen, J., Jia, G., Zhu, Q., 2022. LiDAR Echo Gaussian Decomposition Algorithm for FPGA Implementation. *Sensors* 22 (12), 4628. <https://doi.org/10.3390/s22124628>.