Journal of Geography and Planning
Online ISSN: 2717-3534 Print ISSN: 2008-8078
Homepage: https://geoplanning.tabrizu.ac.ir

Optimization and Evaluation of a Convolutional Neural Network (CNN) for Gully Erosion Susceptibility Prediction in Sheshtamad County

Nadiya Baghaei Nejad[1], Leila Goli Mokhtari[2]✉, Abolghasem Amirahmadi[3], Ali Beheshti[4]

1. Phd student, Department of Climatology and Geomorphology, Faculty of Geography and Environmental Science, Hakim Sabzevari University, Sabzevar, Iran. E-mail: Nadia.baghaei@hsu.ac.ir
2. Corresponding Author, Associate Professor, Department of Climatology and Geomorphology, Faculty of Geography and Environmental Science, Hakim Sabzevari University, Sabzevar, Iran. E-mail: L.mokhtari@hsu.ac.ir
3. Professor, Department of Climatology and Geomorphology, Faculty of Geography and Environmental Science, Hakim Sabzevari University, Sabzevar, Iran. E-mail: amirahmadi@hsu.ac.ir
4. PhD Graduate, Department of Climatology and Geomorphology, Faculty of Geography and Environmental Science, Hakim Sabzevari University, Sabzevar, Iran. E-mail: ali.beheshti@hsu.ac.ir

Article Info

Article type:
Research Article

Article history:
Received: 23 October 2025
Revised: 5 February 2026
Accepted: 18 February 2026
Published: 29 July 2026

Keywords:
Gully Erosion,
Convolutional
Neural Network model,
Feature Selection,
Hyper Parameter Optimization,
Sheshtamad County.

ABSTRACT

Objective: The aim of this study is to evaluate and optimize a Convolutional Neural Network (CNN) model for predicting gully erosion susceptibility in the Sheshtamad region, using a feature selection approach and hyperparameter optimization.

Methodology: In this research, a total of 600 points were identified through field surveys and satellite imagery, comprising 300 gully and 300 non-gully locations. Of these, 70% of the data were used for model training and 30% for validation. Twenty-one environmental factors including topographic, geological, hydrological, and land-use characteristics were selected as predictive variables. Subsequently, the Mutual Information (MI) criterion and the Random Forest algorithm were applied to identify the most influential factors contributing to gully erosion occurrence. Next, the CNN model was developed, and hyperparameter optimization was performed to enhance model performance. The optimized model output was then used to generate a gully erosion susceptibility map, which was evaluated in terms of both accuracy and predictive performance. Given that the study area (Sheshtamad County, western Razavi Khorasan Province) is highly prone to gully erosion, conducting such susceptibility assessments prior to any infrastructural development is essential.

Results: The variable importance analysis revealed that rainfall, distance from rivers, distance from faults, and elevation are the most critical factors influencing gully erosion development. The optimized CNN model, after hyperparameter tuning using the Optuna algorithm, achieved a high prediction accuracy (Accuracy = 0.9338). The resulting susceptibility map indicated that the eastern part of the study area possesses the highest potential for gully erosion occurrence.

Conclusion: The findings demonstrate that the integration of deep learning techniques, particularly the CNN model, with optimal feature selection and hyperparameter tuning provides a powerful framework for accurately predicting gully erosion-prone areas. This approach can support effective soil and water conservation planning and guide sustainable land management policies.

Cite this article: Baghaei Nejad, N., Goli Mokhtari, L., Amirahmadi, A., & Behehshti, A. (2026). Optimization and Evaluation of a Convolutional Neural Network (CNN) for Gully Erosion Susceptibility Prediction in Sheshtamad County. *Journal of Geography and Planning*, 30(97), 438-463. http//doi.org/10.22034/gp.2026.69822.3472

© The Author(s).
Publisher: University of Tabriz.
DOI: http//doi.org/10.22034/gp.2026.69822.3472

Introduction

Soil is one of the most vital issues for environmental sustainability, and soil erosion is a complex process influenced by various factors. This natural phenomenon leads to significant environmental and socio-economic problems, and human activities such as excessive farming and land-use changes have exacerbated it (Arab Amari et al., 2020; Boureli et al., 2020; Hassen & Bantider, 2020; Micić Ponjiger et al., 2021; Wassie, 2020). In arid countries like Iran, soil erosion and sedimentation in dams pose major challenges (Saeidi Hosseini et al., 2018). Gullies, as landforms resulting from fluvial erosion, reduce soil quality and threaten food security (Kader et al., 2022; Salehi et al., 2023; Saljnikov et al., 2023). The annual mean soil erosion rate in Iran has reached about 24 tons per hectare, which is four times the global average. Understanding erosion patterns and sensitivities is essential for protecting natural resources and land management (Mohamadi,2018). Several methods exist to assess erosion, but many have limitations. Recently, machine learning techniques and Geographic Information Systems (GIS) have been used to identify erosion-susceptible areas. This study aims to leverage the capabilities of machine learning to produce precise susceptibility maps and to identify high-risk zones.

Data and Method

This research has designed a combined approach to predict gully erosion maps using deep learning methods. The stages of this study include data collection, selection of the most effective input variables, design and training of deep learning models, and evaluation of the results' accuracy. Data were collected both with and without gullies, comprising 600 sample points (300 points with gullies and 300 points without). These data were obtained through field operations and satellite images and were divided into training (70%) and validation (30%) sets. 22 independent variables, including slope, elevation, rainfall, and topographic indices, were selected. In the preprocessing stage, the most effective variables were chosen to reduce computational complexity and improve model efficiency. To determine the importance of factors affecting gully erosion, two algorithms, Mutual Information (MI) and Random Forest, were utilized.

Results and Discussion

Gully erosion is a significant environmental challenge that has considerable impacts on ecosystems and infrastructure. Identifying and determining the importance of factors influencing gully erosion is essential. To achieve this important objective, several steps were taken, including identifying key factors. The most influential factors were selected using two methods: Mutual Information (MI) and Random Forest. In the second step, hyperparameter optimization was performed using the OPTUNA method, resulting in a gully erosion sensitivity map produced by the CNN algorithm. In the final stage, the model's performance was assessed using the Receiver Operating Characteristic (ROC) curve and evaluated by Kappa coefficient, Mean Squared Error (MSE), Matthew's Correlation Coefficient (MCC), and Root Mean Squared Error (RMSE).

Gully Erosion Sensitivity Map (GES)

The gully erosion sensitivity map was generated using the Convolutional Neural Network (CNN) algorithm and classified into five sensitivity classes. The results indicate that the very high sensitivity class is primarily located in the eastern part of the area, while the very low sensitivity class is found in the northern and southern sections. This study evaluated the accuracy of the gully erosion sensitivity map using the ROC curve. The ROC curve serves as a tool for assessing the predictive quality of models in environmental sciences, and the area under the curve (AUC) is a measure of the model's predictive accuracy. In this research, the AUC of the CNN model was calculated to be 0.97, indicating good model performance in predicting gully erosion. Additionally, the model's performance was evaluated using various assessment metrics, including Kappa coefficient, Mean Squared Error (MSE), Matthew's Correlation Coefficient (MCC), and Root Mean Squared Error (RMSE). The results showed that RMSE was 0.2571 and MSE was 0.0661, indicating low average error between predicted and actual values. Furthermore, MCC was 0.8677 and Kappa was 0.8677, demonstrating a strong correlation between predictions and actual labels. The AUC was 0.9704, and accuracy was 0.9338, confirming the model's high capability to distinguish between erosion-sensitive and non-sensitive classes.

Conclusion

Gully erosion is a soil degradation process with significant environmental and economic consequences. This research utilized the CNN model to identify and predict gully erosion. The results indicate that deep learning models, particularly CNNs, achieve higher accuracy compared to traditional models and provide improvements in prediction accuracy and adaptability to environmental changes. The factors influencing erosion include rainfall amount, distance from rivers, and elevation. The CNN model, with an accuracy of 0.9338, has effectively predicted the potential for gully erosion. The sensitivity map revealed that the eastern part of the area

is most sensitive to erosion, while the northern and southern parts exhibit the least sensitivity. Over 36% of the area falls into the high and very high sensitivity classes, emphasizing the need for erosion management. The findings of this study can aid in formulating soil and water conservation policies, and it is recommended that protective measures be implemented in erosion-sensitive areas.

Keywords: Gully Erosion, Convolutional Neural Network model, Feature Selection, Hyper Parameter Optimization, Sheshtamad County.

جغرافیا و برنامه ریزی
شاپا چاپی: ۸۰۷۸-۲۰۰۸ شاپا الکترونیکی: ۳۵۳۴-۲۷۱۷
Homepage: https://geoplanning.tabrizu.ac.ir

بهینه‌سازی و ارزیابی شبکه عصبی پیچشی (CNN) برای پیش‌بینی حساسیت به فرسایش خندقی درشهرستان ششتمد

نادیا بقائی‌نژاد[۱]، لیلا گلی مختاری[۲]✉، ابوالقاسم امیراحمدی[۳]، علی بهشتی[۴]

۱. دانشجوی دکتری، گروه آب‌وهواشناسی و ژئومورفولوژی، دانشکده جغرافیا و علوم محیطی، دانشگاه حکیم سبزواری، سبزوار، ایران. رایانامه: Nadia.baghaei@hsu.ac.ir

۲. نویسنده مسئول، دانشیار، گروه آب‌وهواشناسی و ژئومورفولوژی، دانشکده جغرافیا و علوم محیطی، دانشگاه حکیم سبزواری، سبزوار، ایران. رایانامه: L.mokhtari@hsu.ac.ir

۳. استاد، گروه آب‌وهواشناسی و ژئومورفولوژی، دانشکده جغرافیا و علوم محیطی، دانشگاه حکیم سبزواری، سبزوار، ایران. رایانامه: abcdef@amirahmadi@hsu.ac.ir

۴. دانش‌آموخته دکتری، گروه آب‌وهواشناسی و ژئومورفولوژی، دانشکده جغرافیا و علوم محیطی، دانشگاه حکیم سبزواری، سبزوار، ایران. رایانامه: ali.beheshti@hsu.ac.ir

اطلاعات مقاله

نوع مقاله:
مقاله پژوهشی

تاریخ دریافت: ۱۴۰۴/۰۸/۰۱
تاریخ بازنگری: ۱۴۰۴/۱۱/۱۶
تاریخ پذیرش: ۱۴۰۴/۱۱/۲۹
تاریخ انتشار: ۱۴۰۵/۰۵/۰۷

کلیدواژه‌ها:
فرسایش خندقی،
مدل شبکه عصبی پیچشی،
انتخاب ویژگی،
بهینه سازی هایپرپارامترها،
شهرستان ششتمد.

چکیده

هدف: هدف از این پژوهش، ارزیابی و بهینه‌سازی مدل شبکه عصبی کانولوشنی (CNN) برای پیش‌بینی پتانسیل فرسایش خندقی در محدوده شهرستان ششتمد با استفاده از رویکرد انتخاب ویژگی و همچنین تنظیم هایپرپارامترها است.

روش پژوهش: بدین منظور در این تحقیق، ۶۰۰ نقطه با بهره‌گیری از بازدیدهای میدانی و تصاویر گوگل ارث شناسایی شد. از این میان، ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد برای اعتبارسنجی مدل اختصاص یافت. تعداد ۲۲ عامل محیطی شامل ویژگی‌های توپوگرافی، زمین‌شناسی، هیدرولوژیکی و کاربری اراضی به‌عنوان متغیرهای مؤثر انتخاب شد و سپس دو روش معیار اطلاعات متقابل (MI) و الگوریتم جنگل تصادفی برای شناسایی عوامل کلیدی مؤثر بر وقوع فرسایش خندقی به‌کار گرفته شدند. در گام بعد مدلسازی بر اساس الگوریتم CNN انجام شد و بهینه سازی هایپرپارامترها در جهت بهبود کارایی مدل اعمال گردید. نقشه حساسیت به فرسایش با استفاده از خروجی مدل بهینه سازی شده، تهیه و مورد ارزیابی صحت و عملکرد قرار گرفت. باتوجه به اینکه منطقه مورد مطالعه (شهرستان ششتمد در غرب خراسان رضوی) از نواحی حساس به فرسایش خندقی به شمار می‌رود، انجام ارزیابی حساسیت قبل از هرگونه فعالیت عمرانی در این منطقه ضروری است.

نتایج: نتایج تحلیل اهمیت متغیرها نشان داد که بارندگی، فاصله از رودخانه، فاصله از گسل و ارتفاع از مهم‌ترین عوامل مؤثر بر توسعه فرسایش خندقی هستند. نقشه حساسیت تولید شده با مدل CNN پس از تنظیم هایپرپارامترها با الگوریتم Optuna توانست دقت بالای(accuracy=/09338) عملکرد خود را نشان دهد. نقشه حساسیت فرسایش خندقی نیز بیانگر آن است که بخش شرقی منطقه بیشترین پتانسیل وقوع فرسایش را داراست.

نتیجه گیری: یافته‌های پژوهش نشان می‌دهد که استفاده از روش‌های یادگیری عمیق به‌ویژه مدلCNN، همراه با انتخاب ویژگی‌های بهینه و تنظیم هایپرپارامترها می‌تواند ابزار قدرتمندی برای پیش‌بینی دقیق نواحی مستعد فرسایش خندقی فراهم آورد و در تدوین برنامه‌های مدیریتی و سیاست‌های حفاظت از خاک و آب مؤثر واقع شود.

استناد: بقائی‌نژاد، نادیا؛ گلی مختاری، لیلا؛ امیراحمدی، ابوالقاسم و بهشتی، علی (۱۴۰۵). بهینه‌سازی و ارزیابی شبکه عصبی پیچشی (CNN) برای پیش‌بینی حساسیت به فرسایش خندقی درشهرستان ششتمد. *جغرافیا و برنامه‌ریزی*، ۳۰ (۹۷)، ۴۳۸-۴۶۳.
http//doi.org/10.22034/gp.2026.69822.3472

ناشر: دانشگاه تبریز.
© نویسندگان.

مقدمه

خاک از حیاتی‌ترین مسائل برای پایداری محیط‌زیست است که نیاز انسانی و معیشت را در سطح زمین تأمین می‌کند. بنابراین کاهش پدیده تخریب زمین یکی از چالش‌های پیشرو برای توسعه پایدار محیط‌زیست و فعالیت‌های اقتصادی است و از این جهت برنامه‌ریزی و مدیریت همه‌جانبه و حفاظت در برابر فرسایش امری ضروری است (عرب عامری و همکاران، ۲۰۲۱). فرسایش خاک، فرآیندی پیچیده است که تحت تأثیر عوامل متعددی از جمله پوشش گیاهی، کاربری اراضی، توپوگرافی، ویژگی‌های خاک، اقلیم و شیوه‌های مدیریت زمین قرار دارد (اسدی و همکاران، ۲۰۲۴). هنگامی‌که بارندگی یا جریان آب از مقاومت خاک بیشتر شود، لایه سطحی خاک جدا شده و فرآیند فرسایش آغاز می‌شود (شاکر و میشرا، ۲۰۲۲). این پدیده طبیعی رایج، باعث ایجاد مسائل زیست‌محیطی و اجتماعی–اقتصادی قابل توجهی می‌شود (حسان و بانتیدر[1]، ۲۰۲۰؛ میچیچ پونجیگر[2] و همکاران، ۲۰۲۱؛ واسی[3]، ۲۰۲۰). در سال‌های اخیر، فعالیت‌های انسانی مانند کشاورزی بی‌رویه، ساخت و ساز و تغییرات کاربری اراضی، این فرآیند را تشدید کرده و تبدیل به بحران زیست‌محیطی بزرگ شده است (الخرابشه و همکاران، ۲۰۱۳). در کشورهایی مانند ایران، با اقلیم خشک و نیمه‌خشک، فرسایش خاک و انباشت رسوب در سدها از جمله چالش‌های مهم است که خسارات اقتصادی و محیط زیستی قابل توجهی دارد (ساجدی حسینی و همکاران، ۲۰۱۸).

فرسایش خندقی یکی از مخاطره آمیز ترین انواع فرسایش آبی است که موجب تخریب اراضی و برهم خوردن تعادل منابع زیستی و محیط زیست می‌شود (وثوقی و همکاران، ۱۴۰۳) و نتایج زیانباری چون بیابان‌زائی، کاهش حاصلخیزی خاک، افزایش سیلاب‌ها و بار رسوب آنها و تاثیرگذاری بر سازه‌های هیدرولیکی می‌شود (کریمی و همکاران، ۱۳۹۹). گالی‌ها که از جمله مهمترین لندفرم‌های ژئومورفولوژیکی حاصل از فرسایش آبی در ارتباط با تخریب خاک هستند (کری[4] و همکاران، ۲۰۰۱) با تمرکز رواناب در شیارها و توسعه عمودی و افقی، باعث می‌شوند مواد آلی و معدنی در مناطق مستعد فرسایش از خاک شسته شوند و منجر به کاهش آب در دسترس برای گیاهان، نفوذ ضعیف و شرایط نامطلوب زهکشی خاک می‌شوند (کادر و همکاران[5]، ۲۰۲۲؛ نائورم و همکاران[6]، ۲۰۲۳). کاهش خاک و زوال حاصلخیزی در کوتاه‌مدت به سختی جبران می‌شود و منجر به فرسایش خاک و از بین رفتن کیفیت خاک می‌شود که تهدیدی جدی برای امنیت غذایی محسوب می‌شود (صالحی[7] و همکاران، ۲۰۲۳؛ سالجنی‌کوف و همکاران[8]، ۲۰۲۳). گالی‌ها می‌توانند از وسط دامنه یا از پای دامنه به سمت پایین رشد نمایند و یا در امتداد کف دره گسترش یابند (گودی[9]، ۲۰۰۳؛ بهرامی و پارسیانی، ۱۴۰۱). با توجه به نظر کارشناسان اکولوژیکی ایران که میانگین فرسایش سالیانه خاک در جهان را ۳۳ تن در هکتار می‌دانند (مخدوم، ۱۳۹۰)، و متوسط نرخ سالانه فرسایش خاک در ایران حدود ۱۶ تن در هکتار می‌باشد که چهار برابر بیشتر از میانگین سالانه در سراسر جهان است (افشار و همکاران، ۲۰۱۰). در تحقیقات اخیر این میزان به ۲۴ تن در هکتار رسیده است (محمدی، ۱۳۹۷). مطالعه، تجزیه و تحلیل و نقشه‌برداری از حساسیت به فرسایش، فراتر از ارزش علمی آن، کاملاً ضروری به نظر می‌رسد. درک الگوها و حساسیت‌های فرسایش برای حفاظت از منابع طبیعی ضروری و هدایت روش‌های موفق مدیریت زمین بسیار مهم است. معادله جهانی فرسایش خاک اصلاح‌شده[10] (بامو و همکاران، ۲۰۲۳)، ابزار ارزیابی خاک و آب[11] (بریاک[12] و همکاران، ۲۰۱۶؛ اکوگدالی و همکاران[13]، ۲۰۲۲؛ اولالی و همکاران[14]، ۲۰۲۰)، تکنیک‌های

1. Hassen & Bantider
2. Mici´c Ponjiger
3. Wassie
4. Carey
5. Kader
6. Naorem
7. Salhi
8. Saljnikov
9. Goudie
10. *RUSLE*
11. SWAT
12. Briak
13. Echogdali
14. Elaloui

ردیابی رادیوایزوتوپ Pb^{210} (موستاکیم[1] و همکاران، ۲۰۲۲) و روش پتانسیل فرسایش[2] (العلوی و همکاران، ۲۰۲۲) در این زمینه مورد استفاده قرار گرفته است. با این حال، این مدل‌ها محدودیت‌های متعددی دارند. به جز *EPM*، اکثر این رویکردها و مدل‌ها نتایجی را ارائه می‌دهند که عمدتاً مربوط به فرسایش ورقه‌ای است. با این حال، فرسایش شیاری و خندقی مسئول بیشتر موادی هستند که در پایین‌دست حوضه‌های آبخیز جریان می‌یابند. این رویکردها اغلب فرآیندهای فرسایشی پیچیده را ساده می‌کنند که ممکن است منجر به تقریب شود. در سال‌های اخیر، فنون یادگیری ماشین و سامانه‌های اطلاعات جغرافیایی در شناسایی مناطق حساس به فرسایش خندقی به کار گرفته شده‌اند و به افزایش دقت و سرعت ارزیابی پتانسیل فرسایش کمک کرده‌اند (اسدی نلیوان و همکاران، ۱۴۰۲). این مدل‌ها می‌توانند به عنوان روشی موفق در این نوع از ارزیابی‌ها تلقی شوند (معماریان خلیل آباد و دمنه، ۱۴۰۳). این مطالعه با هدف پر کردن شکاف‌های موجود در روش‌های ارزیابی فرسایش با استفاده از قابلیت‌های یادگیری ماشین برای تولید نقشه‌های حساسیت دقیق و کاربردی انجام شده است. هدف اصلی مدیریت ریسک فرسایش خندقی، شناسایی و مکان‌یابی مناطق در معرض خطر بالا می‌باشد. با این هدف که رهیافت‌های پیشگیرانه به‌موقع در منطقه به کار گرفته شوند. همچنین عوامل موثر در وقوع این پدیده شناسایی و تحلیل شوند.

پیشینه پژوهش

فرسایش گالی به ویژه فرسایش خاک توسط گالی‌ها یکی از مسائل مهم و اصلی بازدارنده برای تحقق توسعه اقتصادی و اجتماعی به دلیل تخریب منابع زیست محیطی قلمداد می‌شود (حسین‌زاده و همکاران، ۱۳۸۹). این تهدید منجر به ایجاد تغییرات نابهنجار در منظر زمین، تخریب اراضی، از بین رفتن خاک، کاهش فعالیت‌های کشاورزی، جاری شدن سیل و جابجایی حجم قابل توجهی از رسوبات می‌شود. جنبه‌های مختلف فرسایش گالی هنوز کاملاً شناسایی نشده و نمی‌توان با قاطعیت شکل‌گیری و تحول گالی‌ها را به عوامل محدودی نسبت داد. مطالعه فرسایش گالی به سال‌های پیش از ۱۹۳۹ در ایالات متحده برمی‌گردد. در ایران مطالعات متعددی در خصوص گالی‌ها در نواحی مختلف توسط محققین مختلف از جمله نظری سامانی و همکاران (۱۳۸۸) در منطقه بوشهر، سلیمان‌پور و همکاران (۱۳۸۹) در نیریز فارس، رفاهی (۱۳۷۵)، بیاتی خطیبی (۱۳۸۳) در دامنه‌های شمالی گوش‌داغ، جعفری گرزین و کاویان (۱۳۸۸) در حوضه آبخیز سرخ آباد مازندران انجام گرفته است. نقطه مشترک در تمام پژوهش‌های صورت گرفته استفاده از روش‌های سنتی در پهنه بندی گالی می‌باشد در حالیکه در روش‌های جدید استفاده از یادگیری ماشین تنها چند مورد به صورت محدود از این روش نوین برای پهنه بندی فرسایش خندقی استفاده شده است که در زیر به بیان نتایج هر پژوهش به اختصار پرداخته می‌شود.

۱. مطالعات داخلی

شهبازی و وکیلی تجری (۱۴۰۰) در آخرین پژوهش خود با هدف تعیین عرصه‌های حساس به فرسایش‌خندقی و اولویت‌بندی عوامل مؤثر بر آن در استان کرمانشاه، با استفاده از روش حداکثر آنتروپی اقدام به تهیه نقشه پتانسیل فرسایش خندقی نمودند. آنها در این پژوهش از ۹ عامل موثر شامل ارتفاع، شیب، جهت شیب، لیتولوژی، کاربری اراضی، شاخص رطوبت توپوگرافی، انحناء سطح، تراکم آبراهه استفاده کردند و نقشهٔ حساسیت را برای استان کرمانشاه به کمک الگوریتم‌های یادگیری ماشین بدست آوردند. نتایج این پژوهش نشان داد که هم خطی بین عوامل مورد استفاده وجود ندارد و از بین عوامل یاد شده عوامل لیتولوژی، شیب، ارتفاع و تراکم آبراهه به ترتیب مهم-ترین عوامل تأثیرگذار بر حساسیت وقوع فرسایش خندقی بودند. داوودی و محمدی (۱۴۰۱) با استفاده از روش‌های SVM و MARS به بررسی دقت نقشه حساسیت‌پذیری فرسایش آبکندی در حوزه آبخیز شازند پرداختند. نتایج تحقیق آنها بیانگر این است که یافته‌های بدست آمدهٔ حاصل از استفاده از یادگیری ماشین می‌تواند ابزار مفیدی برای مدیریت منابع طبیعی و محیطزیست و همچنین کاهش تخریب خاک باشد. تیموریان و همکاران (۱۴۰۱) در پژوهش خود در استان فارس، نقشه احتمال رخداد فرسایش خندقی را با مدل یادگیری ماشین بیشینه آنتروپی تهیه کردند. آنها در

1. Moustakim
2. *EPM*

این پژوهش از متغیرهای مرتبط با ویژگی‌های زمینی و به ویژه خاک بهره‌گیری کردند. بنا بر نظر این پژوهشگران، مدل به کار برده شده توسط آنها به خوبی توانست فرسایش خندقی را در این منطقه ارزیابی کند. بر پایه یافته‌های آنان مشخص شد بیشترین حساسیت فرسایش خندقی در جنوب استان فارس می‌باشد و این نقشه می‌تواند جزء نقشه‌های پایه برای آمایش سرزمین، مدیران و مهندسان شهرسازی، راهسازی، منابع طبیعی و کشاورزی باشد. اسدی نیلوان و همکاران (۱۴۰۲) با استفاده از مدل‌های CART، ANN و RF به پهنه‌بندی حساسیت فرسایش خندقی در یک حوضه آبخیز با مساحت ۲۲۲ هزار هکتار در اراضی لسی واقع در شمال شرق کشور پرداختند. آنها در پژوهش خود دریافتند استفاده از یادگیری ماشین باعث افزایش دقت و سرعت در زمینه ارزیابی، پتانسیل فرسایش خندقی می‌شود که این فن‌ها در تعیین عوامل موثر بر فرسایش خندقی نیز موثر می‌باشد. مددی و همکاران (۱۴۰۲) در پژوهش خود با استفاده از ماشین بردار پشتیبان (SVM) و درخت رگرسیون تقویت‌شده (BRT) جهت مدل‌سازی حساسیت فرسایش خندقی درحوضه آبخیز رودخانه شور به پیش بینی نقشهٔ حساسیت به فرسایش در شهرستان مهر پرداختند. معماریان خلیل آباد و مومنی دمنه (۱۴۰۳) در پژوهشی با عنوان ارزیابی کارآیی مدل‌های مختلف یادگیری ماشین در تهیه نقشه اشکال فرسایش حوضه‌های آبخیز مناطق خشک به مدل سازی انواع فرسایش آبی با استفاده از یادگیری ماشین در حوضه آبخیز مختاران استان خراسان جنوبی پرداخته‌اند. در این مطالعه، با استفاده از ۲۵ متغیر محیطی و ۱۰ مدل یادگیری ماشین در نرم‌افزار R، تلاش شده است تا پایداری و دقت مدل‌ها در پیش‌بینی انواع فرسایش آبی مورد ارزیابی قرار گیرد.بر اساس یافته‌ها، مدل اجماعی Ensemble Models بهترین عملکرد را در پیش‌بینی فرسایش آبی نشان داده و دقت‌های بسیار بالایی برای اشکال مختلف فرسایش ایجاد کرده است. همچنین، بررسی عوامل مؤثر بر پراکنش فرسایش آبی نشان‌دهنده تأثیر قابل‌توجه متغیرهایی مانند فیزیوگرافی، زمین‌شناسی، پوشش سطحی و خاک‌شناسی در این زمینه است.نتایج این پژوهش می‌تواند به عنوان پایه‌ای برای برنامه‌ریزی کاربری اراضی و مدیریت مؤثر ریسک فرسایش در حوضه‌های آبخیز دیگر مورد استفاده قرار گیرد. داوودی و همکاران (۱۴۰۴) در پژوهش خود به ارزیابی مناطق مستعد رخداد فرسایش خندقی در حوضه آبریز الشتر با استفاده از مدلهای یادگیری ماشین پرداختند. نتایج پژوهش آنان نشان داد که مدل BLM با AUC برابر با ۰/۸۴ عملکرد بهتری در شناسایی مناطق پرخطر فرسایش خندقی نسبت به مدل‌های GLM و BRT دارد. تحلیل اهمیت متغیرهای مورداستفاده در مدلسازی نشان داد که فاصله از رودخانه، شاخص رطوبت توپوگرافی (TWI)، واحدهای زمین شناسی، شاخص زبری سطح (TRI) و میزان بارش، تأثیرگذارترین عوامل در وقوع پدیده فرسایش خندقی هستند. ذاکری نژاد و کهرانی (۱۴۰۴)، در پژوهش خود با عنوان ارزیابی حساسیت فرسایش آبکندی و شناسایی عوامل موثر آن در حوضه آبخیز خسویه در استان فارس با استفاده از مدل‌های TreeNet نقشهٔ پیش‌بینی فرسایش آبکندی را با استفاده از چندین متغیر تهیه کرده‌اند. در پژوهش یاد شده مهم‌ترین متغیره شامل ارتفاع، کاربری اراضی، فرسایش‌پذیری خاک، عمق آبراهه و فاصله از آبراهه می‌باشد. یافته‌های آنها نشان می‌دهد که نواحی کم شیب و کم ارتفاع در مرکز حوضه دارای بیشترین کلاس خطر بوده در حالی که نواحی مرتفع حوضه در نواحی مرزی منطقه مورد مطالعه در کلاس خطر کم قرار دارند.

۲. مطالعات خارجی

در زمینهٔ فرسایش آبکندی در خارج از ایران مطالعاتی صورت گرفته است. که به اختصار به ذکر چند مورد پرداخته می‌شود. گاین[1] و همکاران (۲۰۱۹) با چهار مدل یادگیری ماشین، شامل خط های وایازی افزودنی چندمتغیره، تحلیل تفکیکی، جنگل تصادفی، و ماشین بردار پشتیبان نقشه‌های حساسیت به فرسایش خندقی را بدست آوردند. یافته‌های سطح زیر منحنی بدست آمده توسط آنان در این نوع از یادگیری نشان داد که دقت پیش بینی مدل جنگل تصادفی نسبت به دیگر مدل‌های بیشتر می‌باشد. عرب عامری و همکاران (۲۰۱۹)، در پژوهش خود با عنوان پهنه‌بندی فرسایش خندقی با استفاده از تلفیق رگرسیون وزنی جغرافیایی و مدل‌های ضریب اطمینان و جنگل تصادفی در GIS به تهیه نقشه پهنه بندی فرسایش خندقی در حوضه آبخیز مهابیا ایران پرداختند. آنها برای نیل به اهداف خود ابتدا متغیرهای وابسته و مستقل، که شامل نقشه موجود فرسایش خندقی (GEIM) و

1. Gayen

عوامل مؤثر مرتبط با خندق (GRCFs)، با استفاده از چندین منبع داده را تهیه کرده و برای تحلیل هم‌خطی چندگانه از شاخص‌های تحمل و عامل تورم واریانس استفاده شد. نتایج تحلیل تأیید کرد که هیچ هم‌خطی بین GRCFها وجود ندارد. در مجموع ۱۲ عامل توپوگرافی، هیدرولوژیکی، زمین‌شناسی، اقلیمی، محیطی و خاک مرتبط و ۱۵۰ مکان خندق برای مدل‌سازی استفاده شد. حوزه آبخیز به هشت واحد همگن تقسیم شد زیرا سطح اهمیت پارامترها در بخش‌های مختلف حوزه آبخیز یکسان نیست. برای این منظور از ضرایب پارامترهای ارتفاع، فاصله از آبراهه و فاصله از جاده استفاده شد. این ضرایب با استخراج هسته دو مربعی و AIC از طریق روش GWR بدست آمدند. متعاقباً، مدل یکپارچه RF-CF در هر واحد اعمال شد. در نهایت، با ترکیب واحدها، نقشه نهایی حساسیت به فرسایش خندقی به دست آمد. بر اساس مدل RF، فاصله تا آبراهه، فاصله تا جاده و کاربری/پوشش زمین تأثیر زیادی بر تشکیل خندق نشان دادند. عرب عامری و همکاران (۲۰۲۰) در پژوهش خود به مقایسهٔ میزان حساسیت فرسایش خندقی در شمال ایران با استفاده از یادگیری ماشین پرداختند. آنها در این تحقیق از ۳ اکستنشن درخت تصمیم به نام‌های درخت تصمیم متناوب (ADTree)، درخت ساده و بی‌نظیر (NBTree) و درخت مدل لجستیک (LMT) استفاده کردند. آنها در ضمن پژوهش خود به این نتیجه رسیدند که در بین این سه نمونه درخت مدل لجستیک از لحاظ پیش‌بینی برای این نوع فرسایش معقول تر می‌باشد.کیانگ وانگ[1] و همکاران (۲۰۲۴) به ارزیابی حساسیت فرسایش خندقی با استفاده از مدل‌های پهپاد و هیبریدی مبتنی بر یادگیری ماشین پرداختند و سه مدل هیبریدی، به نام‌های MOORA-FR-RF، MOORA-FR-LG، وMOORA-FR-CB برای ایجاد نقشه حساسیت فرسایش خندقی (GESM)توسط آنها مورد استفاده قرار گرفتند. نتایج پژوهش آنها نشان داد که MOORA-FR-LG جزءکارآمدترین روش‌ها برای پیش بینی حساسیت فرسایش خندقی در حوضه مورد مطالعه است و این نتایج در جهت اقدامات پیشگیری از فرسایش خندقی در مناطق خشک و نیمه خشک مفید است. بامو و همکاران (۲۰۲۴) با استفاده از هفت مدل یادگیری ماشین شامل ML، SVM، KNN، RF، XGBoost، ANN، DT، و LR حساسیت فرسایش خندقی در حوضه آبریز تنسیفت مراکش ارزیابی کردند و فرسایش خندقی را با استفاده از مدل‌های گفته شده برای این حوضه پیش بینی کردند. در این مطالعه از XGBoost و KNN به‌عنوان امیدوارکننده‌ترین مدل‌ها نام بردند. نکته جدید این تحقیق رویکرد نوآورانه آن برای مبارزه با فرسایش خندقی از طریق مدل‌های پیشرفته ML، ارائه راه‌حل‌های عملی برای حفاظت از حوضه آبخیز، مدیریت پایدار و جلوگیری از تخریب زمین است. حسنوزمان[2] و همکاران (2025) در مطالعهٔ خود با استفاده از دو مدل یادگیری ماشین به نام‌های RF و XGB به همراه یک روش تصمیم گیری چند میاره به ارزیابی آسیب پذیری فرسایش خندقی در حاشیهٔ فلات چوتاناگر هند پرداختند. در پژوهش آنان مدل XGB نسبت به سایر عملکرد بهتری داشته به طوریکه دقت پیش‌بینی در این مدل ۹۰/۲۲ درصد بدست آمده است.

معرفی منطقه مورد مطالعه

شهرستان ششتمد یکی از شهرستان‌های غرب استان خراسان رضوی است که درسال ۱۳۱۸ شمسی به عنوان یکی از بخش‌های جنوبی شهرستان سبزوار برگزیده شد. این شهرستان با ارتفاع ۱۳۴۰ متر از سطح آب های آزاد بین ۵۷ درجه و ۳۰ دقیقه تا ۵۸ درجه و ۲۲ دقیقه طول شرقی و ۳۵ درجه و ۲۸ دقیقه تا ۳۶ درجه و ۸ دقیقه عرض شمالی درجنوب شهرستان سبزوار قرار دارد. منطقهٔ مورد مطالعه شامل ۴ بخش با نام‌های شامکان، بیهق (ششتمد)، ربع شامات و تکاب کوه می‌باشد. شهرستان ششتمد با مساحت ۳۰۵۳ کیلومتر مربع دارای ۲۰۳ روستا و ۵۹۵۶ خانوار می‌باشد شکل (۱).

1. Qian Wang
2. Hasanuzzaman

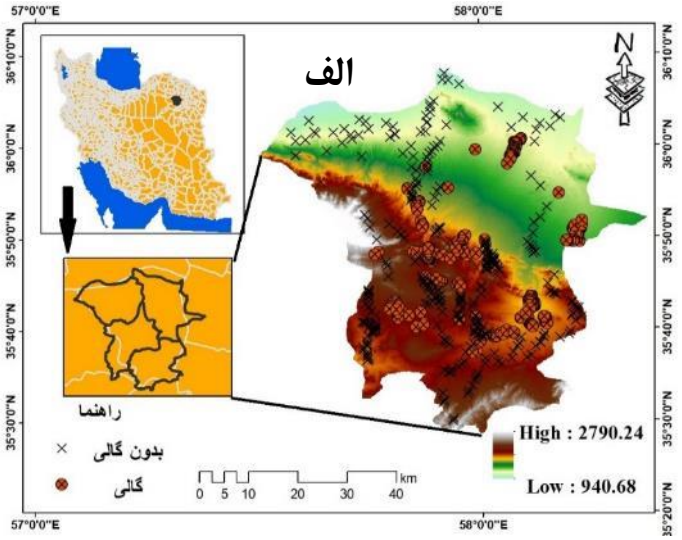





شکل ۱. الف) نقشه منطقهٔ مورد مطالعه به همراه نقاط برداشت شده ب) تصاویر بازدید میدانی از خندق‌های شناسایی شده

روش پژوهش

در این پژوهش، به منظور پیش‌بینی نقشه فرسایش خندقی با بهره‌گیری از روش‌های یادگیری عمیق ماشین، یک رویکرد ترکیبی و منسجم طراحی شده است که شامل مراحلی از جمع‌آوری داده‌ها، فاکتورهای مورد استفاده، انتخاب مؤثرترین متغیرهای ورودی و طراحی و آموزش مدل‌های یادگیری عمیق، و ارزیابی صحت و دقت نتایج می‌باشد. داده‌های مورد نیازاین پژوهش به صورت گالی و بدون گالی جمع‌آوری شده‌اند و مجموعه‌ای شامل ۶۰۰ نقطه نمونه انتخاب شده است که از این میان ۳۰۰ نقطه دارای گالی و ۳۰۰ نقطه بدون گالی هستند. محدوده این نقاط ابتدا از طریق تصاویر گوگل ارث تعیین و در بازدید های میدانی ثبت گردید و پس از آن به دو بخش داده‌های آموزشی (۷۰ درصد) و اعتبارسنجی (۳۰ درصد) تقسیم شدند. براساس عملیات میدانی گسترده جهت شناسایی خندق ها، شرایط محیطی منطقه، دسترسی به داده‌های مورد نیاز جهت پردازش در نرم افزارGIS (لایهٔ رقومی ارتفاعی، خاک شناسی، لیتولوژی و...) و مرور گسترده ادبیات تحقیق، ۲۲ متغیر مستقل انتخاب شده‌اند؛ از جمله شیب، ارتفاع، جهت شیب، انحنای شیب، بارندگی، انحنای نیمرخ، کابری اراضی، لیتولوژی، تراکم گسل، فاصله از گسل‌های موجود در شهرستان، تراکم آبراهه، فاصله از آبراهه، فاصله از جاده، انحنای سطح، خاک‌شناسی، شاخص‌های توپوگرافی مانند TPI، TWI، TRI، SPI، CTI،STI (شکل۲، جدول ۱). در فرایند پیش‌پردازش داده‌ها، انتخاب مؤثرترین متغیرهای ورودی به عنوان گام کلیدی در کاهش پیچیدگی محاسباتی و بهبود کارایی مدل در نظر گرفته شد. در این پژوهش از دو الگوریتم Mutual Information (MI) و Random Forest برای تعیین اهمیت عواملی که بر فرسایش گالی اثر می‌گذارند استفاده شد. در ادامه به ارائه اطلاعاتی در رابطه با انتخاب موثرترین متغیرهای ورودی پرداخته می‌شود.

جدول ۱. مشخصات نقشه‌های عوامل موثر و منبع تهیه آنها

ردیف	نام پارامتر یا داده مکانی	منبع تهیه
۱	شیب	**DEM ALOS PALSAR 12.5m**
۲	ارتفاع	DEM ALOS PALSAR 12.5m
۳	جهت شیب	DEM ALOS PALSAR 12.5m
۴	انحنا	DEM ALOS PALSAR 12.5m
۵	بارندگی	ایستگاههای سازمان هواشناسی
۶	انحنای نیمرخ	DEM ALOS PALSAR 12.5m
۷	کابری اراضی	نقشه کاربری اراضی
۸	لیتولوژی	نقشه زمین شناسی سازمان زمین شناسی
۹	تراکم گسل	نقشه گسلهای ایران
۱۰	فاصله از گسل	نقشه گسلهای ایران
۱۱	تراکم آبراهه	DEM ALOS PALSAR 12.5m
۱۲	فاصله از آبراهه	DEM ALOS PALSAR 12.5m
۱۳	فاصله از جاده	نقشه جاده‌های سراسرکشور
۱۴	انحنای سطح	DEM ALOS PALSAR 12.5m
۱۵	خاک‌شناسی	نقشه نوع خاک موسسه آب و خاک
۱۶	TPI	DEM ALOS PALSAR 12.5m
۱۷	TWI	DEM ALOS PALSAR 12.5m
۱۸	TRI	DEM ALOS PALSAR 12.5m
۱۹	SPI	DEM ALOS PALSAR 12.5m
۲۰	STI	DEM ALOS PALSAR 12.5m
۲۱	LS	DEM ALOS PALSAR 12.5m
۲۲	CTI	DEM ALOS PALSAR 12.5m

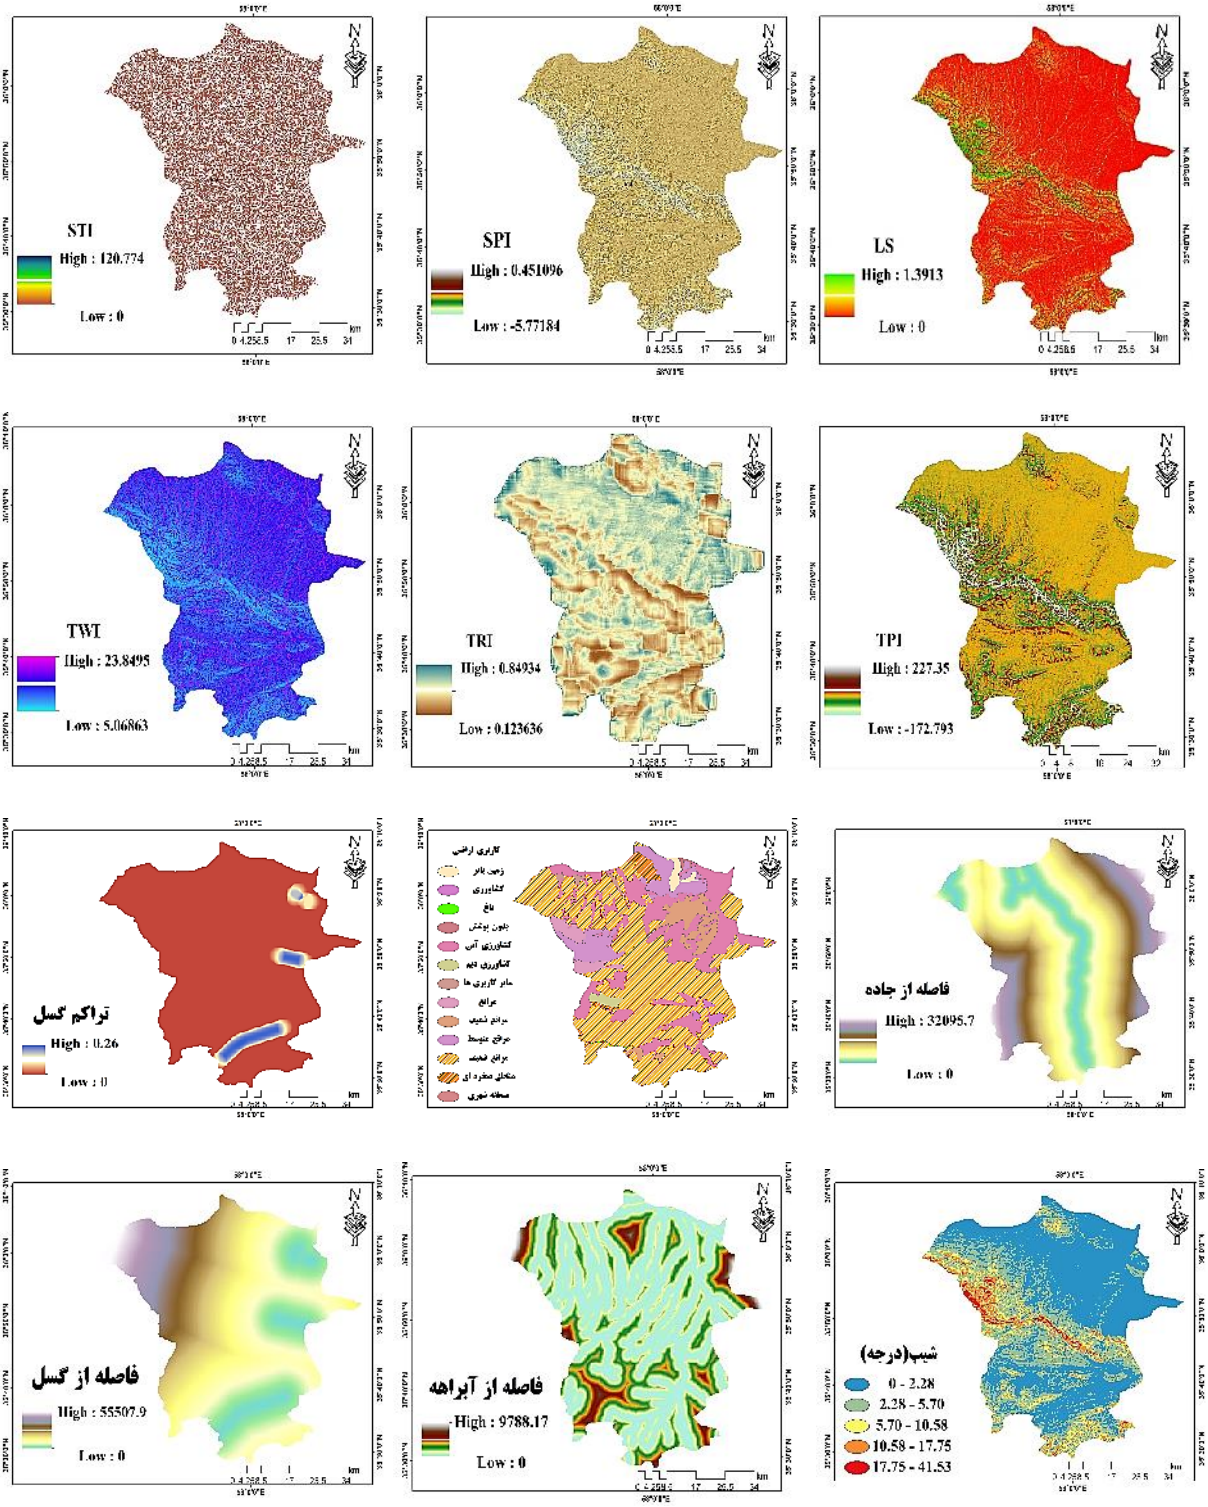

شکل ۲. پارامترهای محیطی مؤثر در فرسایش خندقی

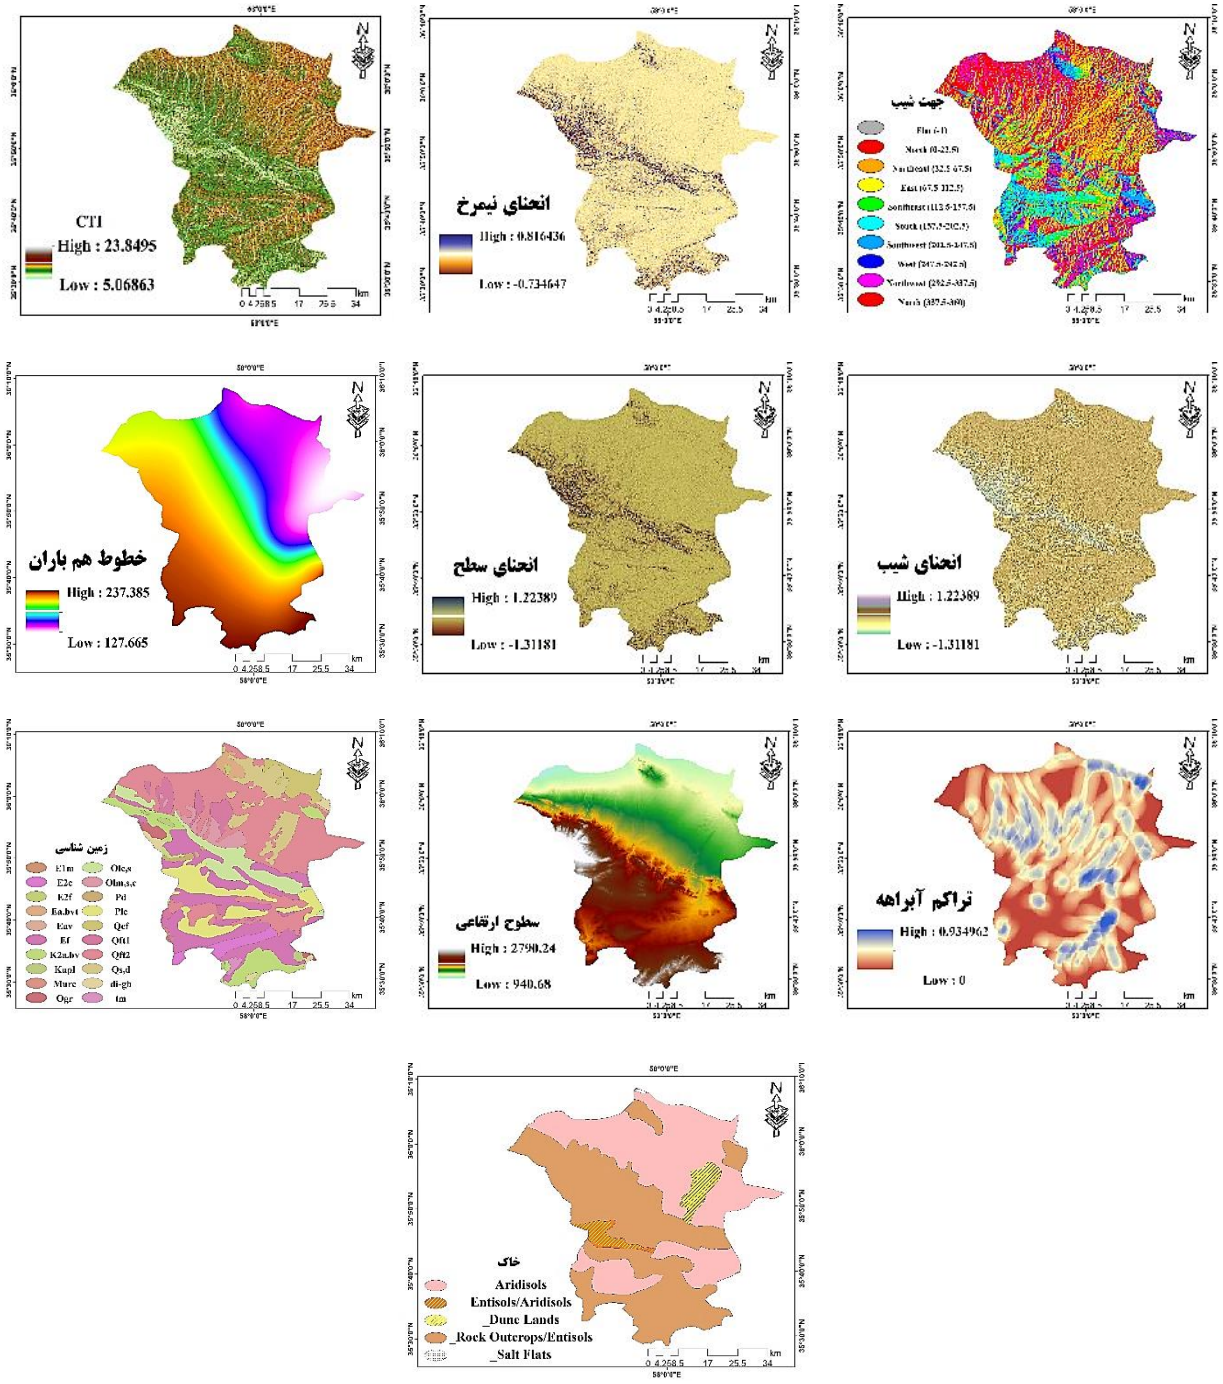

شکل ۲. ادامه پارامترهای محیطی مؤثر در فرسایش خندقی

انتخاب موثرترین متغیرهای ورودی

در فرآیند پیش‌پردازش داده‌ها، انتخاب ویژگی نقش مهمی در تجزیه و تحلیل کمی داده‌های سری زمانی چندبعدی ایفا می‌کند (هیانگ[1] و همکاران، ۲۰۲۴) و موجب کاهش پیچیدگی محاسباتی، جلوگیری از پیچیدگی ابعادی، کاهش زمان آموزش و بهبود کارایی پیش‌بینی‌دهنده می‌شود. بنابراین، باید فهمید که چگونه به‌طور مؤثری ویژگی‌های اصلی سیستم را استخراج کنیم تا

1. Huang

کارایی مدل بهبود یابد (خایر و دهنالکشمی[1]، ۲۰۲۲). براساس تحقیقات پیشین، روش‌های انتخاب ویژگی را می‌توان تقریباً به سه دسته (مالدونادو[2] و همکاران، ۲۰۲۲) شامل فیلتر، پوشش و جاسازی‌شده، بر اساس رابطه‌شان با روش‌های یادگیری (سانگ[3] و همکاران، ۲۰۲۱) تقسیم‌بندی کرد. در این پژوهش از معیار اطلاعات متقابل (Mutual Information) و الگوریتم جنگل تصادفی (Random Forest) برای تعیین اهمیت عواملی که بر فرسایش گالی اثر می‌گذارند استفاده شد. در ادامه به اختصار درباره این دو رویکرد شرح داده می‌شود:

۱. انتخاب ویژگی بر اساس معیار MI (Mutual Information)

روش MI، معیاری از وابستگی متقابل بین دو متغیر است که عمدتاً نشان‌دهنده همبستگی بین آنهاست. با فرض اینکه توزیع احتمال مشترک دو متغیر تصادفی X و Y برابر با $p(x,y)$ و توزیع احتمال حاشیه‌ای آنها به ترتیب $p(x)$ و $p(y)$ باشد، آنگاه اطلاعات متقابل $MI(X,Y)$ برابر با واگرایی کولبک–لیبلر توزیع احتمال مشترک $p(x,y)$ و توزیع احتمال حاشیه‌ای $p(x)$ و $p(y)$ است که به صورت رابطه زیر تعریف می‌شود.

$$ML(x,y) = -f_x f_Y f_{xy}(x,y)\log -\frac{f_{xy}(x,y)}{f_x(x) f y^{(y)}}\, dx d_y \qquad \text{رابطه ۱)}$$

از تعریف بالا، وقتی متغیرها کاملاً مستقل یا متقابلاً مستقل باشند، اطلاعات متقابل آنها کمترین مقدار را دارد. هرچه اطلاعات متقابل بین متغیرها بیشتر باشد، همبستگی قوی‌تر است. در پردازش داده‌ها، ویژگی‌هایی با اطلاعات متقابل بزرگ با متغیر هدف باید تا حد امکان انتخاب شوند تا توانایی پیش‌بینی الگوریتم بهبود یابد و ویژگی‌هایی با اطلاعات متقابل کوچک باید حذف شوند تا افزونگی داده‌ها کاهش یابد، یعنی به اصطلاح انتخاب ویژگی بر اساس حداکثر همبستگی و حداقل افزونگی (پنگ[4] و همکاران، ۲۰۰۵).

۲. انتخاب ویژگی بر اساس الگوریتم جنگل تصادفی (Random Forest)

جنگل تصادفی با جمع‌آوری رأی‌های ترکیبی از چند درخت تصمیم بر پایه ضریب جینی کار می‌کند. واز گره ریشه آغاز می‌شود؛ هر درخت تصمیم ضریب جینی ویژگی‌ها را محاسبه می‌کند و به‌طور عمودی مجموعه داده را تقسیم می‌کند تا گره‌های ابتدایی تا بالاتری که از پیش تعیین‌شده‌اند را ایجاد کنند. ضریب جینی میزان ناخالصی نمونه‌ها را اندازه‌گیری می‌کند؛ بنابراین مقدار کمتر نشان‌دهنده گرهی با خلوص بیشتر است. مقدار اهمیت ویژگی (VIM) امتیازی است که توانایی ویژگی‌ها در کاهش ضریب جینی را می‌سنجد و به‌عنوان معیار حیاتی در انتخاب ویژگی در جنگل تصادفی به کار می‌رود. برخلاف ضریب جینی، نمره بالای VIM برای یک ویژگی نشان‌دهنده توانایی بیشتر در تفکیک بین دسته‌های مختلف است. بالعکس، نمره پایین‌تر نشان می‌دهد که ویژگی در طبقه‌بندی کارایی کمتری دارد و ممکن است نیاز به حذف داشته باشد (دینگ و همکاران[5]، ۲۰۲۵). با استفاده از معادله (شماره دو) ضریب جینی ویژگی xj را در گره درخت تصمیم می‌توان محاسبه کرد:

$$Gini(x_j) = \sum_{j=1}^{k} Pj(1-p_j) = 1 - \sum_{j=1}^{k} P_i^2 \qquad \text{رابطه ۲)}$$

1. Khaire&Dhanalakshm
2. Maldonado
3. Song
4. Peng
5. Ding

که در آن $\mathcal{K}$ تعداد کلاس‌ها و pi احتمال تعلق نمونه به کلاس iام است.

امتیاز VIM ویژگی xj را در گره درخت تصمیم محاسبه کنید: فرض کنید گره n از درخت تصمیم شامل ویژگی xj باشد و گره‌های جانشین چپ و راست گره n، گره l و گره r باشند. امتیاز VIM ویژگی xj در گره n برابر است با:

$$VIM_{Jn}^{(Gini)} = GI_n - GI_i - GI_r$$ رابطه ۳)

که در آن GIn، GIl و GIr به ترتیب ضرایب جینی ویژگی xj را در گره n، گره جانشین چپ l و گره جانشین راست r نشان می‌دهند.

پس از محاسبه امتیاز VIM، ویژگی‌ها بر اساس امتیازشان به ترتیب نزولی رتبه‌بندی می‌شوند. دو استراتژی برای انتخاب ویژگی‌ها وجود دارد. اولین استراتژی شامل انتخاب تعداد مشخصی از ویژگی‌ها بر اساس رتبه‌بندی آنها از بالاترین به پایین‌ترین است، در حالی که استراتژی دوم شامل انتخاب ویژگی‌هایی با امتیاز اهمیت است که از یک آستانه از پیش تعیین‌شده فراتر می‌روند. انتخاب بین این دو استراتژی وابسته به کاربرد است. استراتژی اول باید زمانی انتخاب شود که مدل تعداد از پیش تعریف‌شده‌ای از ویژگی‌های ورودی داشته باشد. بر اساس آستانه، استراتژی دوم انعطاف‌پذیرتر است و فقط ویژگی‌هایی را که به طور قابل توجهی به مدل کمک می‌کنند، حفظ می‌کند، اگرچه این ممکن است منجر به تعداد متفاوتی از ویژگی‌ها بین مجموعه داده‌ها شود.

رهیافت مدلسازی

شبکه عصبی کانولوشنی (CNN)

هسته اصلی رویکرد این مطالعه، استفاده از شبکه‌های عصبی کانولوشن (CNN) برای پیش‌بینی خطر از دست رفتن خاک است. شبکه‌های عصبی کانولوشنی انواع مختلفی از شبکه‌های عصبی پیش‌خور با چندین لایه هستند که برخی از آنها شامل یک یا چند پیچش هستند. لایه‌های ورودی، خروجی و پنهان می‌توانند گنجانده شوند. در حالی که لایه پنهان اغلب عملیات ضرب یا ضرب نقطه‌ای را انجام می‌دهد، لایه‌های ورودی و خروجی اهداف خود را به خوبی توضیح می‌دهند. این شبکه را می‌توان با انواع لایه‌های مختلف، از جمله لایه‌های کاملاً متصل، نرمال‌سازی و ادغام نمود (گلی مختاری و همکاران، ۲۰۲۴). CNNها از طریق یک معماری ساده اما دقیق می‌توانند یک مجموعه داده بزرگ را به طور موثر به یک خروجی نگاشت کنند (شکل ۳). به دلیل ساختار اشتراک وزن و تکنیک‌های ادغام که امکان کاهش تعداد پارامترها را فراهم می‌کنند، به ویژه هنگام تجزیه و تحلیل تصاویر بصری، عملکرد بهتری نسبت به DNNها دارند. توجه به این نکته مهم است که CNNها از نظر مکانی ثابت هستند، به این معنی که نمی‌توانند موقعیت یا جهت یک شیء را تشخیص دهند. بنابراین، اگر موقعیت داده‌ها مهم باشد، CNNها ممکن است انتخاب خوبی نباشند.

ارزیابی مدل

در این پژوهش به منظور ارزیابی دقت نقشه حساسیت فرسایش خندقی، از منحنی ویژه عملکرد گیرنده (ROC) استفاده شد. منحنی ROC، روشی برآمده از تئوری تشخیص سیگنال است که به طور گسترده‌ای در علوم محیطی از آن می‌توان بهره گرفت (بگوئریا[1]، ۲۰۰۶). اغلب روشی که دارای مساحت زیر منحنی بیشتر و در واقع به گوشه سمت چپ نزدیک‌تر باشد، عملکرد بهتری را داشته‌است (فاوسِت[2]، ۲۰۰۶). مساحت زیر منحنی (AUC) در منحنی ROC کیفیت پیش‌بینی مدل را نشان می‌دهد (رحمتی و همکاران، ۲۰۱۶). مقادیر AUC بین ۰/۵ تا ۱ متغیر است و هر چه مقدار آن به ۱ نزدیک‌تر باشد، بیانگر دقت پیش‌بینی بالاتر

1. Beguería
2. Fawcett

مدل است (رجمی[1] و همکاران، ۲۰۱۰). در ارزیابی صحت مدل از معیار دقت یا accuracy استفاده می‌شود. accuracy یک معیار اساسی برای ارزیابی عملکرد کلی مدل‌های طبقه‌بندی است که به صورت نسبت نمونه‌های درست پیش‌بینی شده به تعداد کل نمونه‌ها تعریف می‌شود و فرمول محاسبهٔ آن به صورت رابطهٔ ۴ می‌باشد.

$$Accuracy = \frac{T_p + T_N}{T_p + T_N + F_P + F_N}$$ رابطه ۴)

در اینجا، مثبت‌های واقعی (TP)، منفی‌های واقعی (TN)، مثبت‌های کاذب (FP) و منفی‌های کاذب (FN) چهار نتیجه ممکن از نتایج طبقه‌بندی را نشان می‌دهند. TP و TN به ترتیب تعداد پیکسل‌هایی را نشان می‌دهند که به درستی به عنوان پیکسل‌های وقوع خندق و پیکسل‌های عدم وقوع خندق طبقه‌بندی شده‌اند. FP تعداد پیکسل‌های وقوع خندق که به اشتباه به عنوان وقوع خندق طبقه‌بندی شده‌اند را نشان می‌دهد، در حالی که FN تعداد پیکسل‌های وقوع خندق که به اشتباه به عنوان وقوع غیر خندق طبقه‌بندی شده‌اند را نشان می‌دهد.

بهینه سازی هایپرپارامترها

در عصر حاضر، با افزایش پیچیدگی مدل‌های یادگیری ماشین و نیاز به کارایی بالا، بهینه‌سازی ابرپارامترها به عنوان یکی از گام‌های کلیدی در توسعه مدل‌های یادگیری ماشین مطرح می‌شود. در این پژوهش به‌منظور بهبود عملکرد مدل شبکه عصبی کانولوشنی (CNN)، فرایند بهینه‌سازی هایپرپارامترها با استفاده از کتابخانه Optuna انجام شد. OPTUNA یک کتابخانه قدرتمند و پویا برای بهینه‌سازی هوشمند ابرپارامترها است که با فراهم آوردن رابط کاربری ساده و الگوریتم‌های جست‌وجوی پیشرفته، فرایند جست‌وجو را کارآمدتر می‌کند. این ابزار قدرتمن توسط آکیبا و همکاران (۲۰۱۹) منتشر شد. هدف طراحی آن ارائه ابزاری انعطاف‌پذیر، کارآمد و کاربرپسند برای بهینه‌سازی ابرپارامترهای مدل‌های یادگیری ماشین است (لی و همکاران، ۲۰۲۴). این روش بر پایه جستجوی هوشمندانه در فضای پارامترها با استفاده از الگوریتم Tree-structured Parzen Estimator (TPE) عمل می‌کند و با هدف کمینه‌سازی خطا و بیشینه‌سازی دقت مدل در داده‌های اعتبارسنجی به کار گرفته شد.

در این مطالعه، چهار هایپرپارامتر اصلی مدل شامل اندازهٔ دسته (batch size)، نرخ یادگیری (learning rate)، تعداد نرون‌ها در لایه‌های پنهان (hidden dimension) و نرخ حذف تصادفی (dropout rate) برای بهینه‌سازی انتخاب شدند. محدودهٔ جستجوی هر پارامتر بر اساس مطالعات پیشین و آزمون‌های اولیه تعیین شد و Optuna با اجرای چندین تکرار، ترکیب بهینهٔ این پارامترها را شناسایی کرد.

فرایند تنظیم شامل مراحل زیر بود:

۱. تعریف تابع هدف بر اساس دقت یا مقدار AUC داده‌های اعتبارسنجی؛

۲. اجرای فرآیند جستجو با استفاده از TPE؛

۳. ذخیره و مقایسه نتایج هر تکرار برای انتخاب بهترین مجموعه پارامترها.

نتیجهٔ نهایی نشان داد که تنظیم خودکار Optuna باعث بهبود آموزش و افزایش دقت مدل CNN در پیش‌بینی حساسیت به فرسایش خندقی شد.

1. Regmi

نتایج

۱. تعیین اهمیت عوامل

به منظور تعیین مهم ترین عوامل از دو روش Mutual Information (MI) و Random Forest استفاده شد، که در زیر مهم ترین عوامل از دیدگاه این دو روش مورد بررسی قرار میگیرد.

۱-۱. معیار اطلاعات متقابل برای تعیین مهم ترین عوامل (Mutual Information)

در این قسمت، به بررسی ارتباط بین ویژگی‌ها و متغیر هدف پرداخته شده و میزان اطلاعاتی که هر ویژگی درباره متغیر هدف فراهم می‌کند، اندازه‌گیری شده است. با استفاده از روش اطلاعات متقابل (MI)، ۲۲ پارامتر مؤثر در پیش‌بینی فرسایش گالی مورد ارزیابی قرار گرفته و نتایج نشان می‌دهد که از بین تمامی عوامل، مهم‌ترین پارامترهای تأثیرگذار از دیدگاه MI شامل چهار عامل میزان بارندگی، فاصله از رودخانه، فاصله از گسل و ارتفاع می‌باشد شکل(۳). میزان بارندگی به عنوان یکی از عوامل اصلی در فرآیند فرسایش شناخته می‌شود، زیرا بارش‌های شدید می‌توانند باعث افزایش رواناب و در نتیجه، فرسایش خاک شوند. این عامل به ویژه در مناطق با بارش‌های متناوب و شدید، تأثیر زیادی بر شدت فرسایش خندقی دارد. بارش‌های زیاد می‌توانند موجب ایجاد سیلاب‌ها و جابجایی خاک شوند که این امر خود به فرسایش بیشتر منجر می‌گردد. نتایج به‌دست‌آمده با کارهای انجام‌شده توسط بامائو و همکاران[1] (۲۰۲۴) همسو است و از این جهت صحت و قابلیت تعمیم نتایج را افزایش می‌دهد. فاصله از رودخانه نیز یکی از عوامل مهم در فرسایش خندقی است، به‌طوری که مناطق نزدیک به رودخانه‌ها معمولاً در معرض خطر بالاتری برای فرسایش قرار دارند. جریان آب در نزدیکی رودخانه‌ها می‌تواند خاک را شسته و باعث ایجاد خندق‌های عمیق‌تر شود. همچنین، تغییرات در سطح آب رودخانه و نوسانات آن می‌تواند به فرسایش خاک کمک کند. طبق نتایج مدل اطلاعات متقابل، باید گفت که مناطق نزدیک به آبراهه، میزان پتانسیل فرسایشی بیشتری نسبت به سایر طبقات دارند که تا حد زیادی با نتایج گاین و ساها (۲۰۱۷) و بامائو و همکاران (۲۰۲۴) مطابقت دارد. فاصله از گسل به دلیل تأثیرات زمین‌لرزه‌ها و ناپایداری‌های زمین‌شناسی اهمیت دارد، زیرا در مناطق نزدیک به گسل‌ها، زمین‌لرزه‌ها می‌توانند باعث تخریب خاک و ایجاد شرایط مناسب برای فرسایش شوند. همچنین، حرکت‌های زمین‌شناسی می‌توانند ساختار خاک را تغییر دهند و ریسک فرسایش را افزایش دهند. ارتفاع نیز به عنوان یک عامل مهم در فرسایش خندقی شناخته می‌شود و به واسطه تأثیری که بر مواد آلی خاک، تعادل آب در خاک و تولید گونه‌های مختلف می‌گذارد، می‌تواند بر فرسایش خاک اثر بگذارد. در مناطق با ارتفاعات بالاتر، شیب زمین معمولاً بیشتر است و این امر می‌تواند به افزایش سرعت جریان آب و در نتیجه، فرسایش بیشتر منجر شود. همچنین، در ارتفاعات بالا، شرایط اقلیمی می‌تواند به گونه‌ای باشد که بارش‌های شدیدتر و فرسایش بیشتری را به همراه داشته باشد. طبق نتایج حاصل از مدل MI در انتخاب مهم‌ترین ویژگی‌ها، ارتفاع می‌تواند عامل مهمی در زمینه فرسایش خندقی باشد که این نتایج با پژوهش‌های اخیر در زمینه فرسایش مانند حسین‌زاده و همکاران (۱۳۸۸) و ابراهیمی و همکاران (۱۳۹۶) مطابقت دارد. طبق پژوهش اسلم و همکاران (۲۰۲۱)، مناطق مرتفع بیشتر به فرسایش خاک کمک می‌کنند. باید خاطرنشان کرد که کمترین اهمیت عوامل از دیدگاه اطلاعات متقابل (MI) مربوط به چهار پارامتر فاصله از رودخانه، نوع خاک، تراکم گسل و شاخص انتقال آبراهه (STI) می‌باشد که این عوامل به دلیل عدم توانایی در پیش‌بینی متغیر هدف، از مدل‌سازی حذف شدند.

1. Bammou

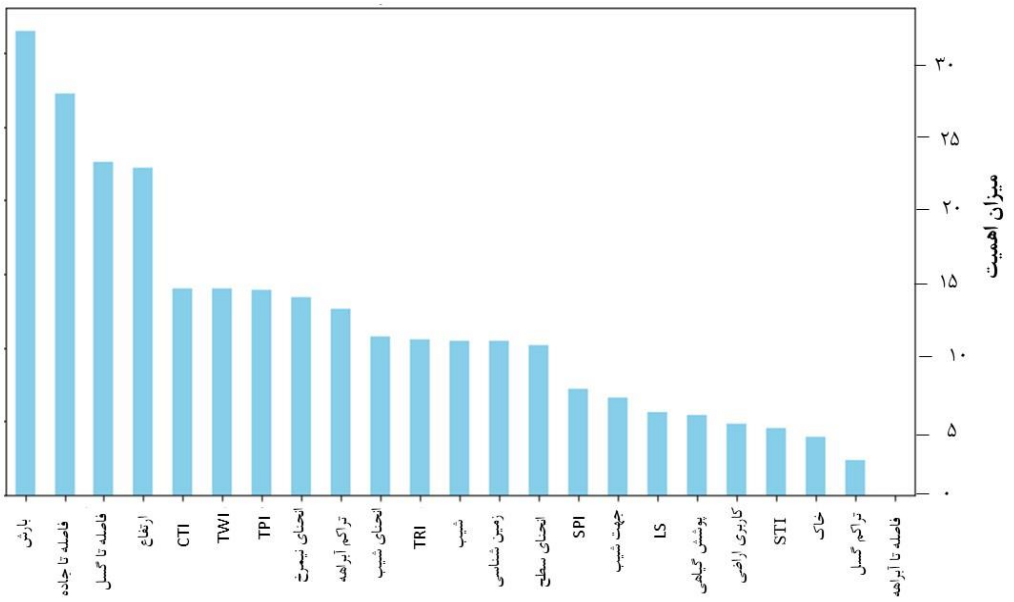

شکل ۳. نتایج تحلیل مهم ترین عوامل با رویکرد اطلاعات متقابل(ML)

۱-۲. الگوریتم جنگل تصادفی برای تعیین مهم ترین عوامل

رویکرد جنگل تصادفی به عنوان یک الگوریتم یادگیری ماشین مبتنی بر درخت تصمیم، نقشی کلیدی در تعیین مهم‌ترین اطلاعات ایفا می‌کند. این روش می‌تواند اهمیت ویژگی‌ها را با توجه به تأثیر آن‌ها بر دقت مدل اندازه‌گیری کند. نتایج این روش نیز تأییدکننده یافته‌ها بود و چهار عامل فاصله تا رودخانه، نوع خاک، تراکم گسل و شاخص کیفیت زمین به عنوان کم‌اهمیت‌ترین عوامل شناسایی شدند. پس از حذف عوامل کم‌اهمیت، تمرکز بر روی عوامل با اهمیت بیشتر قرار گرفت شکل (۴). با بررسی پلات‌های مربوط به اهمیت ویژگی‌ها، می‌توان به تحلیل عوامل زیر پرداخت: فاصله تا جاده یکی از عوامل کلیدی در پیش‌بینی فرسایش خندقی است. اهمیت این عامل به دلیل تأثیرات انسانی و فعالیت‌های مرتبط با جاده‌ها بر روی زمین و پوشش گیاهی مشخص می‌شود. جاده‌ها می‌توانند باعث تغییر در جریان آب، افزایش رواناب و تخریب خاک شوند. همچنین، فعالیت‌های انسانی مانند ساخت و ساز و تردد وسایل نقلیه می‌تواند به فرسایش خاک منجر شود. بنابراین، فاصله از جاده می‌تواند به عنوان یک شاخص مهم در ارزیابی ریسک فرسایش خندقی مورد استفاده قرار گیرد. شاخص موقعیت توپوگرافی نیز به دلیل نقش آن در تعیین شیب و وضعیت زمین اهمیت دارد. این عامل می‌تواند به شناسایی مناطق مستعد فرسایش کمک کند، زیرا تغییرات در شیب زمین تأثیر مستقیمی بر سرعت جریان آب و فرسایش خاک دارد. در بسیاری از مطالعات مشابه، این عامل به عنوان یک فاکتور تأثیرگذار شناخته شده است، زیرا مناطق با شیب‌های تند معمولاً در معرض خطر بالاتری برای فرسایش هستند. بارندگی به عنوان یکی از عوامل اصلی در فرسایش خندقی شناخته می‌شود و اهمیت این عامل به دلیل تأثیر مستقیم آن بر رواناب و قدرت فرسایش آب است. بارش‌های شدید می‌توانند باعث افزایش حجم آب جاری و در نتیجه، فرسایش خاک شوند. نتایج مطالعات نشان می‌دهد که حذف این عامل از مدل‌سازی می‌تواند دقت پیش‌بینی فرسایش خندقی را کاهش دهد، زیرا بارندگی یکی از مهم‌ترین عوامل تعیین‌کننده در وقوع و شدت فرسایش است. فاصله تا گسل نیز به عنوان یک عامل مؤثر در فرسایش خندقی مطرح است. اهمیت این عامل به دلیل تأثیرات زمین‌لرزه‌ها و ناپایداری‌های زمین‌شناسی مشخص می‌شود. مناطق نزدیک به گسل‌ها معمولاً در معرض خطر بیشتری برای فرسایش و ناپایداری خاک هستند، زیرا حرکات زمین ساختی می‌توانند ساختار خاک را تغییر دهند و ریسک فرسایش را افزایش دهند. این عامل، به ویژه در مناطق زلزله‌خیز، می‌تواند تأثیر قابل توجهی بر فرآیند فرسایش داشته باشد. در نهایت، با استفاده از روش‌های MI و جنگل تصادفی، عوامل کم‌اهمیت شناسایی

و حذف شدند. همچنین، عوامل مهم‌تر که تأثیر قابل توجهی بر مدل‌سازی دارند، شناسایی و تحلیل شدند. این نتایج می‌توانند به بهبود دقت پیش‌بینی‌ها و درک بهتر از عوامل مؤثر در مطالعه مورد نظر کمک کنند.

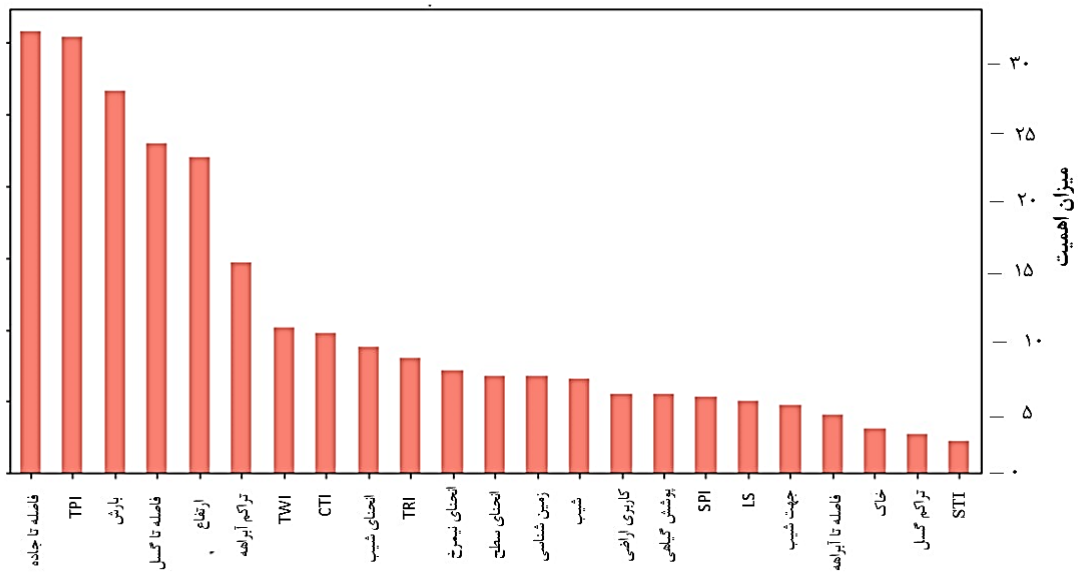

شکل ٤. نتایج تحلیل مهم ترین عوامل با الگوریتم جنگل تصادفی

بهینه سازی هایپرپارامترها

در این پژوهش برای بهینه‌سازی معیارها و زیر معیارهای موثر در هرکدام از مدل‌های پیش بینی فرسایش خندقی از روش OPTUNA استفاده شد. OPTUNA به‌عنوان یک فریمورک بهینه‌سازی هوشمند، فضای پارامترها را به‌صورت پویا و ساختارمند مدل‌سازی می‌کند و با استفاده از samplerهای هوشمند مانند TPE امکان کاوش کارآمد در فضای پیچیده را فراهم می‌نماید. در مطالعه حاضر، که هدف آن پیش‌بینی نقشه فرسایش خندقی با استفاده از یادگیری عمیقCNN است، تنظیم صحیح هایپرپارامترهای مدل نقش بسیار مهمی ایفا می‌کند.

برای این منظور، پس از آزمایش و بررسی مقادیر مختلف، مقادیر بهینه هایپرپارامترها به شرح جدول (۲) تعیین شدند که به ارائه توضیحاتی در خصوص هر مقدار پرداخته می‌شود.

Batch Size: این پارامتر تعداد نمونه‌هایی است که در هر تکرار آموزش به مدل داده می‌شود. این اندازه که در مدل بکار گرفته شده مادل ۱۶ می‌باشد نمایشگر این است که به مدل امکان می‌دهد تا الگوهای محلی را به خوبی شناسایی کرده و در نتیجه نقشه فرسایش خندقی را با دقت بالاتری پیش‌بینی کند.

نرخ یادگیری (Learning Rate): نرخ یادگیری تعیین می‌کند که مدل در هر تکرار آموزش چقدر وزن‌های خود را تغییر دهد. مقدار ۰/۰۰۵۵ باعث می‌شود تا مدل به آرامی و با دقت بالا به سمت حداقل خطا همگرا شود، که این امر در پیش‌بینی دقیق نقشه فرسایش خندقی بسیار حائز اهمیت است.

ابعاد لایه پنهان (Hidden Dimension): این پارامتر تعداد نورون‌های لایه‌های پنهان مدلCNN را مشخص می‌کند. مقدار ۲۱۱ امکان استخراج ویژگی‌های مفید و پیچیده از داده‌های ورودی را فراهم می‌آورد، که در نهایت به پیش‌بینی دقیق‌تر نقشه فرسایش خندقی منجر می‌شود.

نرخ Dropout: یک تکنیک منظم‌سازی است که از بیش‌برازش مدل جلوگیری می‌کند. میزان Dropout ۰/۴۱۱۳ باعث می‌شود تا مدل قادر به تعمیم‌پذیری بهتر بوده و در نتیجه نقشه فرسایش خندقی را با دقت بالاتری پیش‌بینی کند.

در مجموع، تنظیم دقیق این هایپرپارامترها نقش حیاتی در بهبود عملکرد مدل CNN در پیش‌بینی نقشه فرسایش خندقی ایفا می‌کند.

جدول ۲. هایپر پارامترهای اصلی مدل

dropout rate	hidden dimension	learning rate	batch siz
۰/۴۱۱۳	۲۱۱	۰/۰۰۵۵	۱۶

نقشه حساسیت به فرسایشی خندقی(GES)

نقشه حساسیت فرسایش خندقی با استفاده از الگوریتم شبکه عصبی کانولوشنی (CNN) تهیه شد شکل (۵). نقشه مذکور به پنج کلاس خیلی کم، کم، متوسط، زیاد و خیلی زیاد طبقه بندی شد. بر اساس شکل (۵) کلاس حساسیت خیلی زیاد عمدتاً در بخش شرقی منطقه مطالعاتی قرار گرفته که به دلیل وجود سازندهای مارنی حساس به فرسایش، توپوگرافی تپه ماهوری و وجود پوشش‌گیاهی بسیار تنک و تا حدودی عدم پوشش‌گیاهی در این منطقه بوده و در مقابل کلاس حساسیت خیلی‌کم در بخشهای شمال و جنوب منطقه مطالعاتی قرار گرفته که به دلیل پوشش گیاهی متراکم و وجود زمینهای کشاورزی و باغات و همچنین توپوگرافی هموار در این منطقه، فرسایش در این بخشها بسیار ناچیز است و امکان تشکیل گالی در این مناطق وجود ندارد. مساحت هر یک از کلاسهای حساسیت در جدول ۳ نشان داده شده است. بر اساس جدول ۳، از کل منطقه به مساحت ۱۸۱۸ کیلومتر مربع، ۴۰/۴۳ درصد (۱۲۳۵/۵۸ کیلومترمربع) در کلاس حساسیت خیلی کم، ۱۲/۵۹ درصد (۳۸۴/۹۶ کیلومترمربع) در کلاس حساسیت کم، ۱۰/۰۸ درصد (۳۰۸/۱۷ کیلومترمربع) در طبقه حساسیت متوسط و ۱۰/۷۷ درصد (۳۲۹/۲۱ کیلومترمربع) در کلاس حساسیت زیاد و ۲۶/۱۰ درصد (۷۹۷/۷۸ کیلومترمربع) در کلاس حساسیت خیلی زیاد قرار گرفته است.

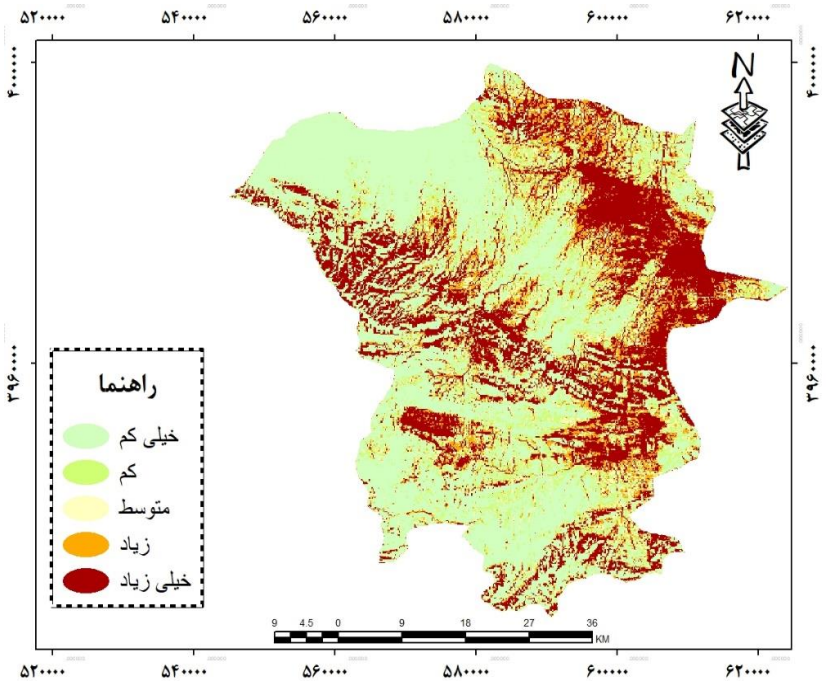

شکل ۵. نقشه حساسیت به فرسایشی خندقی با الگوریتم CNN

جدول ۳. کلاس‌های حساسیت فرسایش خندقی با الگوریتم CNN

کلاس های حساسیت	خیلی کم	کم	متوسط	زیاد	خیلی زیاد
مساحت (km2)	۱۲۳۵,۵۸	۳۸۴/۹۶	۳۰۸/۱۷	۳۲۹/۲۱	۷۹۷/۷۸
درصد	۴۰/۴۳	۱۲/۵۹	۱۰/۰۸	۱۰/۷۷	۲۶/۱۰

صحت سنجی مدل

در این پژوهش به منظور ارزیابی دقت نقشه حساسیت فرسایش خندقی، از منحنی ویژه عملکرد گیرنده (ROC) استفاده شد. منحنی ROC، روشی برآمده از تئوری تشخیص سیگنال است که به طور گسترده‌ای در علوم محیطی از آن می‌توان بهره گرفت (بگوئریا، ۲۰۰۶). اغلب روشی که دارای مساحت زیر منحنی بیشتر و در واقع به گوشه سمت چپ نزدیک‌تر باشد، عملکرد بهتری را داشته‌است (فاوسِت، ۲۰۰۶). مساحت زیر منحنی (AUC) در منحنی ROC کیفیت پیش‌بینی مدل را نشان می‌دهد (رحمتی و همکاران، ۲۰۱۶). مقادیر AUC بین ۰/۵ تا ۱ متغیر است و هر چه مقدار آن به ۱ نزدیک‌تر باشد، بیانگر دقت پیش‌بینی بالاتر مدل است (رجمی[1] و همکاران، ۲۰۱۰). به منظور بررسی دقت مدل به‌کاررفته در تحقیق پیش رو و شناسایی مناطق حساس به فرسایش خندقی، بعد از نقشه حساسیت فرسایش خندقی، با استفاده از روش منحنی عملکرد گیرنده (ROC) سطح زیر منحنی برای مدل مذکور محاسبه شد. با توجه به شکل (۶)، مساحت سطح زیر منحنی در الگوریتم CNN دارای حد مطلوبی و با میزان ۰/۹۷ می‌باشد. در نتیجه می‌توان گفت این مدل به شکل معناداری عملکرد خوبی در پیش‌بینی فرسایش خندقی دارد. این الگوریتم (CNN) به لحاظ تفکیک‌پذیری نمونه‌های با ریسک فرسایش بالا بهتر عمل می‌کند و می‌تواند به عنوان ابزار هشدار سریع و کارآمد در مدیریت منابع و حفاظت از خندق‌ها استفاده شود. مطالعات متعددی از پژوهشگران مانند (عرب عامری و همکاران، ۱۳۹۸؛ ابراهیمی و همکاران، ۱۳۹۶؛ رستمی زاد و همکاران، ۱۳۹۴؛ کانسکنتی و همکاران[2]، ۲۰۱۸؛ آزاره و همکاران[3]، ۲۰۱۹؛ رنگزن و همکاران، ۱۴۰۱) دیگر نشان داده‌اند که منحنی ROC کارآیی مشابهی دارد و در تعیین دقت نقشه‌های فرسایش خندقی مؤثر می‌باشد.

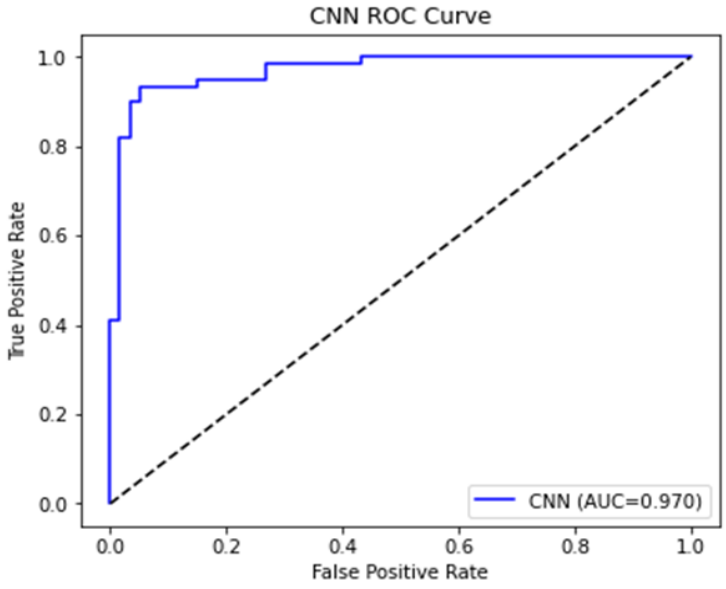

شکل ٦. منحنی ROC برای مدل CNN

1. Regmi
2. Conoscenti
3. Azareh

عملکرد مدل

پس از انجام تحلیل هم‌خطی ROC و ساخت مجموعه داده‌ها، این مطالعه که در پی تهیه نقشه حساسیت به فرسایش خندقی با الگوریتم یادگیری عمیق (CNN) می‌باشد عملکرد مدل ذکر شده با استفاده از معیارهای ارزیابی چندگانه از جمله ضریب کاپا (یک معیار ارزیابی توافقی است که میزان توافق بین پیش‌بینی‌های مدل و برچسب‌های واقعی را اندازه‌گیری می‌کند. مقدار KAPPAبین −۱ تا +۱ است، که +۱ نشان‌دهنده توافق کامل است.)، MSE (معیاری برای میزان خطای مربعی میانگین است. هرچه مقدار MSE کمتر باشد، نشان‌دهنده دقت بیشتر مدل در پیش‌بینی است. MCC (یک معیار ارزیابی دوتایی است که میزان همبستگی بین پیش‌بینی‌های مدل و برچسب‌های واقعی را نشان می‌دهد. مقدار MCC بین −۱ تا +۱ است، که +۱ نشان‌دهنده پیش‌بینی کامل است) جذر میانگین مربعات خطا (RMSE) یک معیار ارزیابی خطای مدل است که میزان انحراف پیش‌بینی‌های مدل از مقادیر واقعی را نشان می‌دهد. هرچه مقدار RMSE کمتر باشد، نشان‌دهنده عملکرد بهتر مدل در پیش‌بینی نقشه فرسایش خندقی است و... کمی‌سازی شد. معیارهای عملکرد مدل در جدول ۴ ارائه شده است.

جدول ٤: معیارهای عملکردی مدل CNN

ACCURACY	AUC	KAPPA	MCC	MSE	RMSE
۰/۹۳۳۸	۰/۹۷۰۴	۰/۸۶۷۷	۰/۸۶۷۷	۰/۰۶۶۱	۰/۲۵۷۱

اندازه‌های اصلی عملکرد مدل CNN مطابق جدول ۴ نشان می‌دهد که:

RMSE به مقدار ۰/۲۵۷۱ و MSE به مقدار ۰/۰۶۶۱ رسیده است که نشان‌دهنده خطای متوسط پایین بین مقادیر پیش‌بینی‌شده و مشاهده‌شده تلفات خاک نسبت به مقادیر هدف است. MCC برابر با ۰/۸۶۷۷ و KAPPA برابر با ۰/۸۶ نشان‌دهنده همبستگی موفق بین گروه‌بندی پیش‌بینی‌شده و برچسب‌های واقعی، و همچنین توافق بالای بین طبقه‌بندی دوکلاسه و چندطبقه است. AUC برابر با ۰/۹۷۰۴ و ACC برابر با ۰/۹۳۳۸ گویای توان بالای مدل در تمایز بین کلاس‌های حساس به فرسایش و غیر حساس، و همچنین کارایی مناسب در وظایف طبقه‌بندی می‌باشد. مطابق جدول ارائه شده مشاهده می‌شود که عملکرد مدل استفاده شده در این پژوهش با دقت ۰/۹۳، سطح زیر منحنی ۰/۹۷، ضریب کاپا برابر با ۰/۸۶ RMSE برابر با ۰/۲۵ و... به عملکرد بهینه ای در تمام معیارهای ارزیابی دست یافته است. این نشان می‌دهد که مدل CNN هم در وظایف طبقه‌بندی و هم در قابلیت‌های رتبه‌بندی عملکرد بسیار خوبی دارد. ارزیابی چندمعیاره با هم نشان می‌دهد که مدل CNN نه‌تنها در وظایف طبقه‌بندی-محض بلکه در وظایف رتبه‌بندی و ترجیحی نیز عملکرد قابل‌توجهی دارد. به عبارتی، مدل توانسته است با استفاده از شاخص‌های مختلف، به سطح عملکردی برسد که در کاربردهای نقشه‌نگاری فرسایش خندقی قابل اتکا باشد و قابلیت تعمیم مناسب را نیز از خود نشان دهد. نتیجه‌های به‌دست‌آمده در این مطالعه با نتایج محققان پیشین مانند (کالیانی و همکاران، ۲۰۲۵؛ میائو[1] و همکاران، ۲۰۲۳؛ لیو[2] و همکاران، ۲۰۲۳؛ لی[3] و همکاران، ۲۰۲۴؛ هلال[4] و همکاران، ۲۰۲۵) در حوزه‌های مشابه هم‌خوانی قابل توجهی دارد. به‌طور خاص، شاخص‌های کارایی مانند ROC-AUC و MCC در بسیاری از مطالعات با روش‌های CNN یا سایر معماری‌های یادگیری عمیق با مقادیر مشابه یا بالاتر گزارش شده است. این هم‌سویی نشان می‌دهد که مدل CNN به‌کارگرفته‌شده در تهیه نقشه حساسیت به فرسایش خندقی، به‌طور پایا و با سطح اعتماد بالایی عمل می‌کند و می‌تواند به‌عنوان گزینه‌ای معتبر برای مدل‌سازی فرسایش در محیط‌های مشابه و داده‌های دیگر مورد استفاده قرار گیرد.

1. Miao
2. Liu
3. Li
4. Hlal

بحث و نتیجه‌گیری

فرسایش خندقی یکی از مهم‌ترین فرآیندهای تخریب خاک و منابع طبیعی است که می‌تواند پیامدهای زیست‌محیطی و اقتصادی قابل‌توجهی به همراه داشته باشد. شناسایی مناطق مستعد این پدیده و ارزیابی عوامل مؤثر بر آن از اهمیت بالایی برخوردار است. در این پژوهش، فرسایش خندقی با استفاده از مدل CNN مورد بررسی و پیش بینی قرار گرفته است. تفاوت استفاده از مدل‌های یادگیری عمیق ماشین و مدل‌های سنتی در این است که پیش‌بینی فرسایش با مدل‌های سنتی فاقد دقت لازم برای مسایل پیچیده و ناهمگن هستند (مختاری وهمکاران، ۲۰۱۸). رویکرد یادگیری عمیق معرفی شده در این تحقیق، از این مدل‌های مرسوم پیشی گرفته و دقت پیش‌بینی بالاتر، وضوح مکانی بهبود یافته و سازگاری بیشتری با تغییرات محیطی ارائه می‌دهد. نتایج بدست آمده از دو الگوریتم MI و جنگل تصادفی در زمینه پارامترهای مؤثر در فرسایش خندقی نشان داد که مهم‌ترین عوامل مؤثر در منطقه مورد مطالعه شامل میزان بارندگی، فاصله از رودخانه، فاصله از گسل و ارتفاع است. در رویکرد MI، این عوامل به عنوان مهم‌ترین فاکتورها شناسایی شدند، در حالی که در الگوریتم RF، فاصله از جاده، شاخص موقعیت توپوگرافی و بارندگی و فاصله از گسل به عنوان مهم‌ترین عوامل معرفی شدند. عملکرد مدل ذکر شده با استفاده از معیارهای ارزیابی چندگانه از جمله ضریب کاپا، MSE، MCC، جذر میانگین مربعات خطا (RMSE) و... کمی‌سازی شد و نشان داد که مدل CNN توانسته است با دقت بالا برابر با۰/۹۳۳۸ پتانسیل فرسایش خندقی را در منطقه پیش‌بینی کند. بررسی نقشه حساسیت فرسایش نشان داد که بخش شرقی منطقه مطالعاتی دارای بیشترین حساسیت به فرسایش خندقی است که به دلیل وجود سازندهای مارنی حساس، توپوگرافی تپه‌ماهوری و پوشش گیاهی بسیار تنک است. در مقابل، بخش‌های شمالی و جنوبی منطقه دارای کمترین حساسیت به فرسایش خندقی هستند که به دلیل پوشش گیاهی متراکم، وجود زمین‌های کشاورزی و باغات و توپوگرافی هموار است. بیش از ۳۶ ٪ از کل منطقه مطالعاتی در کلاس حساسیت زیاد و خیلی زیاد قرار دارند که نشان‌دهنده ضرورت مدیریت و کنترل فرسایش در این مناطق است. همچنین، بیش از ۷۰٪ از کل گالی‌های موجود در منطقه در کلاس حساسیت خیلی زیاد قرار دارند که نشان‌دهنده تأثیر شدید عوامل مؤثر بر فرسایش در این مناطق است. در این راستا نتایج تحقیق رنگزن و همکاران (۱۴۰۱)، اسدی نلیوان (۱۴۰۲)، موسوی و همکاران (۱۳۹۹)، رحمتی و همکاران (۲۰۱۷)، عرب عامری (۲۰۱۹)، تین بوی[1] و همکاران (۲۰۱۹)، میائو و همکارن (۲۰۲۳) با نتایج پژوهش حاضر مطابقت دارد. یافته‌های این مطالعه می‌تواند در تدوین سیاست‌ها و برنامه‌های حفاظت از خاک و آب در منطقه مورد استفاده قرار گیرد. تحقیقات آینده باید کاربرد گسترده‌تر مدل‌های یادگیری عمیق را در زمینه‌های محیطی متنوع بررسی کند چرا که استفاده از الگوریتم‌های یادگیری عمیق می‌توانند به عنوان ابزاری مفید در شناسایی مناطق حساس به فرسایش خندقی و برنامه‌ریزی مدیریت آن مورد استفاده قرار گیرند. در این راستا، اجرای اقدامات حفاظتی و کنترلی در مناطق با حساسیت خیلی زیاد به فرسایش خندقی، مانند ایجاد سازه‌های آبخیزداری، بهبود پوشش گیاهی و اجرای عملیات بیولوژیکی توصیه می‌شود.

منابع

ابراهیمی، مجید؛ امیراحمدی، ابوالقاسم و زنگنه اسدی، محمدعلی (۱۳۹۶). مقایسه تهیه نقشه حساسیت به فرسایش آبکندی با استفاده از مدل‌های احتمالاتی وزن واقعه و نسبت فراوانی در حوضه آبخیز سنگانه کلات. *فصل‌نامه تحقیقات جغرافیایی*، ۳۲(۴)، ۱۰۵-۱۲۶. https://doi.org/10.29252/geores.32.4.105

اسدی نلیوان، امید؛ رابط، علیرضا؛ وکیلی تجره، فرزانه؛ رمضانی، مرضیه؛ مومنی، محمد و حیدری، کهزاد (۱۴۰۲). پهنه‌بندی حساسیت فرسایش خندقی با استفاده از مدل‌های CART، ANN و RF. *مهندسی و مدیریت آبخیز*، ۱۵(۲)، ۱۵۵-۱۷۱. https://doi.org/10.22092/ijwmse.2022.356379.1920

1. Tien Bui

بهرامی، شهرام و پارسیانی کاظم (۱۴۰۱). قابلیت پاجوش‌های ریشه درختی در برآورد فرسایش گالی با استفاده از تحلیل دندروژئومورفولوژیک در حوضه نیلکوه (گالیکش)، *استان گلستان. فضای جغرافیایی*. ۲۲(۷۸)، ۷۳-۹۳. https://sid.ir/paper/1006575/fa

بیاتی خطیبی، مریم (۱۳۸۳). فرسایش، فرآیندهای فرسایش و شکل‌های ناشی از آن. *مجله رشد آموز جغرافیا*، ۶۹، ۱۷-۲۴.

تیموریان، تیمور؛ نظری سامانی، علی‌اکبر؛ فیض‌نیا، سادات؛ احمدآلی، خالد و سلیمان‌پور، سیدمسعود (۱۴۰۱). شناخت توزیع مکانی احتمال رخداد فرسایش خندقی با مدل بیشینهٔ آنتروپی. *پژوهش‌های آبخیزداری*، ۳۵(۲)، ۲-۱۵. https://doi.org/10.22092/wmrj.2021.354647.1415

جعفری‌گرزین بهنوش و کاویان عطاا... (۱۳۸۸). ارزیابی وقوع فرسایش خندقی در حوزهٔ آبخیز سرخ آباد مازندران با استفاده از سنجش از دور و سامانه اطلاعات جغرافیایی. *مجله علوم و مهندسی آبخیزداری ایران*. ۳ (۷) :۵۵-۵۸. https://doi.org/20.1001.1.20089554.1388.3.7.7.5

حسین‌زاده، محمد مهدی؛ اسماعیلی، رضا؛ جوری، حسن و پورکلهر، سمانه (۱۳۸۹). طبقه‌بندی گالی‌ها بر مبنای ویژگی‌های مورفومتریک با استفاده از تکنیک آماری چند متغیره (مطالعه موردی : فیروز کلا – نوشهر). *پژوهشهای دانش زمین*، ۱(۳). ۲۹-۴۰. https://doi.org/20.1001.1.20088299.1389.1.3.5.8

داودی‌راد علی اکبر و محمدی مجید (۱۴۰۱). بررسی دقت نقشه حساسیت‌پذیری فرسایش آبکندی با استفاده از روش‌های SVM و MARS در حوزه آبخیز شازند. *مجله علوم ومهندسی آبخیزداری ایران*. ۱۶ (۵۹)، ۱۲-۲۲.

داودی، علی؛ کرم، امیر؛ ضیائیان فیروزآبادی، پرویز و احمدآبادی، علی (۱۴۰۴). ارزیابی مناطق مستعد رخداد فرسایش خندقی در حوضه آبریز الشتر با استفاده از مدل‌های یادگیری ماشین. *سوانح طبیعی*. ۱(۱):۶۳-۸۲. http://dio.org/10.22034/1.1.63

ذاکری‌نژاد، رضا و کهرانی، عباس (۱۴۰۴). ارزیابی حساسیت فرسایش آبکندی و شناسایی عوامل موثر آن در حوضه آبخیز خسویه در استان فارس. *جغرافیا و برنامه‌ریزی*، ۳۰(۹۵)، ۲۲۳-۲۴۳. https://doi.org/10.22034/gp.2025.65173.3342

رفاهی، حسینعلی (۱۳۷۵). *فرسایش آبی و کنترل آن*. چاپ اول، تهران: انتشارات دانشگاه تهران، ۱۴۰-۱۴۷.

رنگزن، کاظم؛ ظاهری عبده وند، زینب و مکرم، مرضیه (۱۴۰۱). تعیین مناطق مستعد فرسایش خندقی با استفاده از تابع عضویت فازی (مطالعه موردی: شهر مهر در جنوب استان فارس). *پژوهشهای ژئومورفولوژی کمّی*، ۱۰(۴)، ۵۶-۷۴. https://doi.org/20.1001.1.22519424.1401.10.4.4.9

سلیمان پور، سیدمسعود؛ صوفی، مجید و احمدی، حسن (۱۳۸۹). بررسی آستانه توپوگرافی و عوامل مؤثر بر رسوب‌زایی و گسترش خندق‌ها در منطقه نی ریز استان فارس. *مرتع و آبخیزداری (منابع طبیعی ایران)*، ۶۳(۱)، ۴۱-۵۲.

شهبازی، خسرو و وکیلی تجره، فرزانه (۱۴۰۰). اولویت‌بندی عوامل مؤثر بر فرسایش خندقی و تعیین پهنه‌های حساس در استان کرمانشاه با استفاده از مدل MaxEnt. *مجله علوم ومهندسی آبخیزداری ایران*. ۱۵ (۵۴)، ۴۸-۵۸.

عرب عامری، علیرضا؛ رضایی، خلیل و یمانی، مجتبی (۱۳۹۸). ارزیابی حساسیت زمین نسبت به فرسایش خندقی با تکنیک دادهکاوی گروهی مطالعه موردی: حوضه شاهرود. *نشریه علوم زمین*. ۲۸(۱۱۱)، ۱۳۹-۱۵۰.

کریمی، سمیه؛ رجبی، معصومه و رضایی‌مقدم، محمدحسین (۱۳۹۹). ارزیابی و پهنه‌بندی فرسایش خاک در مناطق کارستی با استفاده از مدل SMLRK (مطالعه موردی: حوضه الوند، استان کرمانشاه). *جغرافیا و برنامه‌ریزی*، ۲۴(۷۴). ۱۹۷-۲۱۴. https://doi.org/10.22034/gp.2020.10861

محمدی، شاهین؛ کریم‌زاده، حمیدرضا و علیزاده، میثم (۱۳۹۷). برآورد مکانی فرسایش خاک کشور ایران با استفاده از مدل RUSLE. *مجله اکوهیدرولوژی*، ۵(۲)، ۵۵۱-۵۶۹. https://doi.org/10.22059/ije.2018.239777.706

مخدوم، مجید (۱۳۹۰). *شالودهٔ آمایش سرزمین*، تک‌جلد، چاپ ۱۲، تهران: انتشارات دانشگاه تهران، ۲۸۹.

معماریان خلیل‌آباد، هادی و مومنی دمنه، جواد (۱۴۰۳). ارزیابی کارآیی مدل‌های مختلف یادگیری ماشین در تهیه نقشه اشکال فرسایش حوضه‌های آبخیز مناطق خشک (مطالعه موردی: حوزه آبخیز دشت مختاران، خراسان جنوبی). *پژوهش‌های فرسایش محیطی*، ۱۴(۴)، ۱۱۹-۱۴۵.

موسوی، سیدروح‌اله؛ رحمانی، اصغر؛ پارسایی، فرزانه و کوهسار بستانی، محمدحسین (۱۳۹۹). پیش‌بینی مکانی برخی از ویژگی‌های خاک سطحی با استفاده از مدل‌های درونیابی و یادگیری ماشین. *مجله مدیریت خاک و تولید پایدار*، ۱۰(۳)، ۲۷-۴۹. https://doi.org/10.22069/ejsms.2021.17251.1916

نظری سامانی، علی اکبر؛ احمدی، حسن؛ قدوسی، جمال و مقیمی‌نژاد، فیروزه (۱۳۸۸)، تعیین سهم فرسایش خندقی در میزان تولید رسوب با استفاده از ردیابهای آلی و سزیم ۱۳۷، *پنجمین همایش ملی علوم و مهندسی آبخیزداری ایران*، گرگان. https://civilica.com/doc/87170

وثوقی، شیما؛ ذاکری‌نژاد، رضا و انتظاری، مژگان (۱۴۰۳). پیش‌بینی فرسایش خندقی و شناسایی عوامل موثر بر آن با استفاده از مدل حداکثرآنتروپی و مدل‌های تغییر اقلیمی BCC-CSM2-MR برای سال‌های ۲۰۲۰-۲۰۴۰ (مطالعه موردی:حوضه آبخیز علامرودشت). *جغرافیا و برنامه‌ریزی*، (۹۰)۲۸، ۱۶۳-۱۴۱. https://doi.org/10.22034/gp.2023.57572.3169

Afshar, F. A., Ayoubi, S., & Jalalian, A. (2010). Soil redistribution rate and its relationship with soil organic carbon and total nitrogen using 137Cs technique in a cultivated complex hillslope in western Iran. *Journal of Environmental Radioactivity*, 101(8), 606-614. https://doi.org/10.1016/-j.jenvrad.2010.03.008

Ahmad, I., Dar, M. A., Teka, A. H., et al. (2019). Application of hydrological indices for erosion hazard mapping using Spatial Analyst tool. *Environmental Monitoring and Assessment*, 191, 482. https://doi.org/10.1007/s10661-019-7614-x

Akiba, T.; Sano, S.; Yanase, T.; Ohta, T.; Koyama, M. Optuna: A (2019). Next-Generation Hyperparameter Optimization Framework. In Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, Anchorage, AK, USA, ACM: New York, NY, USA, 2019; pp. 2623–2631.

Alkharabsheh, M. M., Alexandridis, T. K., Bilas, G., Misopolinos, N., & Silleos, N. (2013). Impact of land cover change on soil erosion hazard in northern Jordan using remote sensing and GIS. *Procedia Environmental Sciences*, 19, 912-921. https://doi.org/10.1016/j.proenv.2013.06.101

Ebrahimi M, Amir Ahmadi، A Habibolahian M, Zangeneh Asadi M A, Shayan Yeganeh A. Active Tectonic and its Relationship with Volume of the Alluvial Fans (Case Study: Five Basins in North-eastern of Central Iran). *GeoRes* 2016; 30(4), 6-29. [In Persian] URL: http://georesearch.ir/article-1-84-en.html

Asadi Nalivan, O., Rabet, A., Vakili tajareh, F., Ramezani, M., Momeni, M. and Heydari, K. (2023). Zoning gully erosion susceptibility using ANN, CART and RF models. *Watershed Engineering and Management*, 15(2), 155-171. https://doi.org/10.22092/ijwmse.2022.356379.1920. [In Persian]

Asadi, M.Z., Mokhtari, L.G., Zandi, R. *et al*. (2024). Evaluating the effect of the land use change on discharge and flood intensity (case study: sub-basins of Kal-e Shur Sabzevar river basin, Iran). *Sustain. Water Resour. Manag.* 10, 185. https://doi.org/10.1007/s40899-024-01159-3

Aslam, B., Maqsoom, A., Alaloul, W. S., Musarat, M. A., Jabbar, T., & Zafar, A. (2021). Soil erosion susceptibility mapping using a GIS-based multi-criteria decision approach: Case of district Chitral, Pakistan. *Ain Shams Engineering Journal*, 12(2), 1637-1649.

Azareh, A., Rahmati, O., Rafiei-Sardooi, E., Sankey, J. B., Lee, S., Shahabi, H., & Ahmad, B. B. (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.

Arabameri A, Chen W, Loche M, Zhao X, Li Y, Lombardo L, Bui DT. (2020). Comparison of machine learning models for gully erosion susceptibility mapping. *Geoscience Frontiers*, 11(5): 1609–1620.

Arabameri, A., Pradhan, B., & Rezaei, K. (2019). Gully erosion zonation mapping using integrated geographically weighted regression with certainty factor and random forest models in GIS. *Journal of Environmental Management*, 232, 928–942. https://doi.org/10.1016/j.jenvman.2018.11.11

arabameri,A. , rezaei,K. and yamani,M. (2019). assessment land susceptibility to gully erosion using ensemble data-mining Techniques (Case study: Shahroud Basin). *Scientific Quarterly Journal of Geosciences*, 28(111), 139-150. https://doi.org/10.22071/gsj.2018.114756.1374. [InPersian]

Arabameri, A., B. Pradhan and L. Lombardo. (2019). Comparative assessment using boosted regression trees, binary logistic regression, frequency ratio and numerical risk factor for gully erosion susceptibility modelling. *Catena*, 183: 104223.

Bahrami S, parsiani K. (2022). The ability of the root suckers in the estimation of gully erosion by dendrogeomorphological analysis in Nilkooh catchment (Galikesh), *Golestan province*. 22, 73-93. URL: http://geographical-space.iau-ahar.ac.ir/article-1-3475-fa.html. 20.1001.1.1735322.1401.22.-78.4.3 [InPersian]

Bammou, Y., Benzougagh, B., Abdessalam, O., Brahim, I., Kader, S., Spalevic, V., Sestras, P., & Ercis¸li, S. (2024). Machine learning models for gully erosion susceptibility assessment in the Tensift catchment, Haouz Plain, Morocco for sustainable development. *Journal of African Earth Sciences*.

Bammou, Y., Benzougagh, B., Bensaid, A., Igmoullan, B., Al-Quraishi, A. M. F. (2023). Mapping of current and future soil erosion risk in a semi-arid context (Haouz Plain, Marrakech) based on CMIP6 climate models, the analytical hierarchy process (AHP) and RUSLE. *Modeling Earth Systems and Environment*, 1-14. https://doi.org/10.1007/s40808-023-01845-9

Beguería, S. (2006). Validation and evaluation of predictive models in hazard assessment and risk management. *Natural Hazards*, 37, 315-329.

Bayati Khatibi (2004). Erosion, erosion processes and their resulting forms. *Journal of Geography*, Issue 69. [InPersian]

Timurian, Timur, Nazari Samani, Ali Akbar, Feiznia, Sadat, Ahmadali, Khalid, Sulaymanpour, Seyyed Masoud. (1401). Understanding the spatial distribution of the probability of gully erosion with the maximum entropy model. *Watershed Research*, 35(2), 2-15. doi: 10.22092/wmrj.2021.-354647.1415. [In Persian]

Briak, H., Moussadek, R., Aboumaria, K., & Mrabet, R. (2016). Assessing sediment yield in Kalaya gauged watershed (Northern Morocco) using GIS and SWAT model. *International Soil and Water Conservation Research*, 4(3), 177-185. https://doi.org/10.1016/j.iswcr.2016.08.002

Carey, B., Gray, J., & Seagrave, C. (2001). Gully erosion. *Department of Natural Resources and Mines, The State of Queensland*. http://www.gcenvironment.org.au/pdf/LM81w.pdf

Conoscenti, C., Agnesi, V., Cama, N. A., Caraballo-Arias, M., & Rotigliano, E. (2018). Assessment of gully erosion susceptibility using multivariate adaptive regression splines and accounting for terrain connectivity. *Land Degradation and Development*, 29, 724–736.

Davodirad A, Mohammady M. (2022). Accuracy Assessment of Gully Erosion Susceptibility Map Using SVM and MARS Methods in Shazand Watershed. *jwmseir*; 16 (59), 2. [In Persian]

Davoudi A, Karam A, Zeaiean Firouzabadi P, Ahmadabadi A. (2025). Assessment of gully erosion-prone areas in the Aleshtar basin using machine learning models. Natural Disasters, 1 (1): 63-82. http://disaster.ndri.ac.ir/article-1-31-fa.html [In Persian]

Ding, J., Du, J., Wang, H., et al. (2025). A novel two-stage feature selection method based on random forest and improved genetic algorithm for enhancing classification in machine learning. *Scientific Reports*, *15*, 16828. https://doi.org/10.1038/s41598-025-01761-1

Echogdali, F. Z., Kpan, R. B., Ouchchen, M., Id-Belqas, M., Dadi, B., Ikirri, M., & Boutaleb, S. (2022). Spatial prediction of flood frequency analysis in a semi-arid zone: a case study from the Seyad Basin (Guelmim Region, Morocco). In *Geospatial technology for landscape and environmental management: sustainable assessment and planning* (pp. 49–71). https://doi.org/10.1007/978-981-16-7373-3_3

Elaloui, A., Khalki, E. M. E., Namous, M., Ziadi, K., Eloudi, H., Faouzi, E., & Boudhar, A. (2022). Soil erosion under future climate change scenarios in a semi-arid region. *Water*, 15(1), 146. https://doi.org/10.3390/w15010146

Elaloui, A., Marrakchi, C., Fekri, A., Maimouni, S., & Aradi, M. (2017). USLE-based assessment of soil erosion by water in the watershed upstream Tessaoute (Central High Atlas, Morocco). *Modeling Earth Systems and Environment*, 3, 873–885. https://doi.org/10.1007/s40808-017-0340-x

Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874.

Gayen, A., & Saha, S. (2017). Application of weights-of-evidence (WoE) and evidential belief function (EBF) models for the delineation of soil erosion vulnerable zones: a study on Pathro river basin, Jharkhand, India. *Modeling Earth Systems and Environment*, 3(3), 1123-1139.

Gayen, A., Pourghasemi, H.R., Saha, S., Keesstra, S. and Bai, S., 2019. Gully erosion susceptibility assessment and management of hazard-prone areas in India using different machine learning algorithms. *Science of the Total Environment*. 668, 124-138.

Goli Mokhtari, L., Baghaei Nejad, N., & Beheshti, A. (2024). Predicting gully formation: An approach for assessing susceptibility and future risk. *Natural Resource Modeling*, 37, e12409. https://doi.org/10.1111/nrm.12409

Goudie, A. S. (2003). *Encyclopedia of geomorphology*. Routledge.

Hassen, G., & Bantider, A. (2020). Assessment of drivers and dynamics of gully erosion in case of Tabota Koromo and Koromo Danshe watersheds, South Central Ethiopia. *Geoenvironmental Disasters*, 7, 1–13.

Hlal, M., El Monhim, B., Chenal, J., Munyaka, J.-C. B., Azmi, R., Sbai, A., Cwick, G., & Hichou, B. B. (2025). Application of Deep Learning and Geospatial Analysis in Soil Loss Risk in the Moulouya Watershed, Morocco. *Water*, 17(9), 1351. https://doi.org/10.3390/w17091351

Hosseinzadeh, Mohammad Mehdi, Esmaeili, Reza, Jouri, Hassan and Pourkalhar, Samaneh. (2010). Classification of Galleys Based on Morphometric Characteristics Using Multivariate Statistical Techniques (Case Study: Firuz Kola–Nowshahr). Earth Science Research, 1(3), 29-40. [In Persian]

Huang, L., Zhou, X., Shi, L., & Gong, L. (2024). Time Series Feature Selection Method Based on Mutual Information. *Applied Sciences*, 14, 1960. https://doi.org/10.3390/app14051960

Jafarai Gorzin B, Kavian A. (2009). Assessment of Gully Erosion Occurrence in Sorkh-Abad Watershed Using Remote Sensing and Geographical Information System. *Jwmseir*, 3(7), 55-58. https://doi.org/20.1001.1.20089554.1388.3.7.7.5

Kader, S., Novicevic, R., & Jaufer, L. (2022). Soil management in sustainable agriculture: analytical approach for the ammonia removal from the dairy manure. *Journal of Agriculture and Forestry*, 68(4), 69–78. https://doi.org/10.17707/AgricultForest.68.4.06

karimi, S. , Rajabi, M. and Rezaei Moghaddam, M. H. (2021). Evaluation and zoning of soil erosion in karst areas by SMLRK Model (case study of Alvand basin of Kermanshah province). *Journal of Geography and Planning*, 24(74), 197-214. doi: 10.22034/gp.2020.10861. [In Persian]

Khaire, U. M., & Dhanalakshmi, R. (2022). Stability of feature selection algorithm: A review. *Journal of King Saud University - Computer and Information Sciences*, 34, 1060–1073. https://doi.org/10.1016/j.jksuci.2021.03.003

Li, H., Jin, J., Dong, F., Zhang, J., Li, L., & Zhang, Y. (2024). Gully Erosion Susceptibility Prediction Using High-Resolution Data: Evaluation, Comparison, and Improvement of Multiple Machine Learning Models. *Remote Sensing*, 16(24), 4742. https://doi.org/10.3390/rs16244742

Liu, C., Li, H., Xu, J., Gao, W., Shen, X., & Miao, S. (2023). Applying convolutional neural network to predict soil erosion: A case study of coastal areas. *International Journal of Environmental Research and Public Health*, 20(3), 2513. https://doi.org/10.3390/ijerph20032513

Maldonado, J., Riff, M. C., & Neveu, B. (2022). A review of recent approaches on wrapper feature selection for intrusion detection. *Expert Systems with Applications*, 198, 116822. https://doi.org/10.1016/j.eswa.2022.116822

Memarian H, Momeni Damaneh J. Evaluating the efficiency of different machine learning models in extracting the map of erosion forms of arid watersheds (Case study: Mukhtaran plain watershed, South Khorasan, Iran). E.E.R. 2025; 14 (4), 119-145 http://magazine.hormozgan.ac.ir/article-1-856-fa.html [In Persian]

Mici´c Ponjiger, T., Luki´c, T., Basarin, B., Joki´c, M., Wilby, R. L., Pavi´c, D., & Morar, C. (2021). Detailed analysis of spatial–temporal variability of rainfall erosivity and erosivity density in the central and southern Pannonian basin. *Sustainability*, *13*(23), 13355. https://doi.org/10.3390/-su132313355

Miao, S., Liu, Y., Liu, Z., Shen, X., Liu, C., & Gao, W. (2023). A novel attention-based early fusion multi-modal CNN approach to identify soil erosion based on unmanned aerial vehicles. *IEEE Access*, 11. https://doi.org/10.1109/ACCESS.2023.1120000.

Hasanuzzaman, Md., Pravat Shit. (2025). Assessment of gully erosion susceptibility using four data-driven models AHP, FR, RF and XGBoosting machine learning algorithms, *Natural Hazards Research*, 5(1), 36-47.

Makhdoom, Majid, (2011). *Foundation of Land Planning, single volume, 12th edition*, Tehran, Tehran University Press, 289 pages. [In Persian]

Memarian H, Momeni Damaneh J. (2025). Evaluating the efficiency of different machine learning models in extracting the map of erosion forms of arid watersheds (Case study: Mukhtaran plain watershed, South Khorasan, Iran). E.E.R. 14(4), 119-145. : http://magazine.hormozgan.ac.ir/article-1-856-fa.html. https://doi.org/10.61186/jeer.14.4.119 [In Persian]

Mohammadi, S., Karimzadeh, H. and Alizadeh, M. (2018). Spatial estimation of soil erosion in Iran using RUSLE model. *Journal of Ecohydrology*, *5*(2), 551-569. https://doi.org/10.22059/ije.2018.-239777.706 [In Persian]

Mokhtari, L.G., Shafiee, N., & Rahmani, A. (2018). Estimation of Soil Erosion Using the RUSLE Model in Nourabad Mamasani Watershed. *Hydrogeomorphology*. 16(5), 1-21. [In Perian]

Mousavi, S. R., Rahmani, A., Parsaei, F., & Kohsar Bostani, M. H. (2020). Spatial prediction of some surface soil properties using interpolation models and machine learning. *Journal of Soil Management and Sustainable Production*, 10(3), 27-49. https://doi.org/10.22069/ejsms.2021.-17251.1916 [In Persian]

Shahbazi K, Vakili tajareh F. (2021). Prioritization of Effective Factors on Gully Erosion and Determination of Sensitive Areas in Kermanshah Province Using MaxEnt Model. *jwmseir*; 15 (54), 48-58. [In Persian]

Moustakim, M., Benmansour, M., Nouira, A., Benkdad, A., & Damnati, B. (2022). Caesium-137 re-sampling approach and excess Lead-210 sediment dating to assess the impacts of climate change and agricultural practices on soil erosion and sedimentation in Northwest Morocco. *Environmental Earth Sciences*, 81(10), 278. https://doi.org/10.1007/s12665-022-10409-6

Naorem, A., Jayaraman, S., Dang, Y. P., Dalal, R. C., Sinha, N. K., Rao, C. S., & Patra, A. K. (2023). Soil constraints in an arid environment—challenges, prospects, and implications. *Agronomy*, 13(1), 220. https://doi.org/10.3390/agronomy13010220

Nazari Samani, Ali Akbar and Ahmadi, Hassan and Ghodousi, Jamal and Moghimi Nejad, Firoozeh, 2009, Determining the contribution of gully erosion to sediment production using organic and cesium-137 tracers, Fifth National Conference on Watershed Science and Engineering of Iran, *Gorgan*, https://civilica.com/doc/87170 [In Persian]

Teimurian, T. , Nazari Samani, A. , Feiznia, S., Ahmadaali, K. and Soleimanpour, S. M. (2022). Determining the Spatial Distribution of Gully Erosion Probability Using the MaxEnt Model. *Watershed Management Research*, 35(2), 2-15. https://doi.org/10.22092/wmrj.2021.354647.1415

Ouallali, A., Briak, H., Aassoumi, H., Beroho, M., Bouhsane, N., & Moukhchane, M. (2020). Hydrological foretelling uncertainty evaluation of water balance components and sediments yield using a multi-variable optimization approach in an external Rif's catchment, Morocco. *Alexandria Engineering Journal*, 59(2), 775–789. https://doi.org/10.1016/j.aej.2020.02.017

Peng, H., Long, F., & Ding, C. (2005). Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27, 1226–1238. https://doi.org/10.1109/TPAMI.2005.188

Rahmati, O., Haghizadeh, A., Pourghasemi, H. R., & Noormohamadi, F. (2016). Gully erosion susceptibility mapping: The role of GIS-based bivariate statistical models and their comparison. *Natural Hazards*, 82, 1231-1258.

Rahmati, O., N. Tahmasebipour, A. Haghizadeh, H.R. Pourghasemi and B. Feizizadeh. 2017b. Evaluation of different machine learning models for predicting and mapping the susceptibility of gully erosion. *Geomorphology*, 298: 118-137.

Refahi, Hossein Ali. (1996). *Water erosion and its control*. First edition, Tehran University Press, pp. 140-147. [In Persian]

Regmi, N. R., Giardino, J. R., & Vitek, J. D. (2010). Modeling susceptibility to landslides using the weight of evidence approach: Western Colorado, USA. *Geomorphology*, 115, 172-187.

Salhi, A., El Hasnaoui, Y., Pérez Cutillas, P., & Heggy, E. (2023). Soil erosion and hydroclimatic hazards in major African port cities: The case study of Tangier. *Scientific Reports*, 13(1), 13158. https://doi.org/10.1038/s41598-023-40135-3

Rangzan,K. , zaheri Abdehvand,Z. and Mokarram,M. (2022). Determining areas prone to gully erosion using fuzzy membership function(Case study: Mohr City in the south of Fars province). *Quantitative Geomorphological Research*, 10(4), 56-74. 20.1001.1.22519424.1401.-10.4.4.9 [In Persian]

Sajedi-Hosseini, F., Choubin, B., Solaimani, K., Cerdà, A., & Kavian, A. (2018). Spatial prediction of soil erosion susceptibility using a fuzzy analytical network process: Application of the fuzzy decision-making trial and evaluation laboratory approach. *Land Degradation & Development*, 29(9), 3092-3103. https://doi.org/10.1002/ldr.3058

Saljnikov, E., Lavrishchev, A., Rombke, J., Rinklebe, J., Scherber, C., Wilke, B.-M., & Eulenstein, F. (2022). Understanding and monitoring chemical and biological soil degradation. In *Advances in Understanding Soil Degradation* (pp. 75-124). https://doi.org/10.1007/978-3-030-85682-3_3

Song, X., Zhang, Y., Gong, D., & Sun, X. (2021). Feature selection using bare-bones particle swarm optimization with mutual information. *Pattern Recognition*, 112, 107804. https://doi.org/10.1016/-j.patcog.2020.107804

Soleimanpour, S., Soufi, M., and Ahmadi, H. (2010). A Study on the Topographic Threshold and Effective Factors on Sediment Production and Gully Development in Neyriz,Fars Province. *Journal of Range and Watershed Managment*, 63(1), 41-52. [In Persian]

Tien Bui, D., A. Shirzadi, H. Shahabi, K. Chapi, E. Omidvar, B. Thai Pham, D. Talebpour, H. Khaledian, B. Pradhan, M. Panahi, B. Ahmad, H. Rahmani, G. Grof and S. Lee. (2019). A novel ensemble artificial intelligence approach for gully erosion mapping in a semi-arid watershed (Iran). *Sensors*, 19: 2444.

Qian Wang, B., 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*, 244, 106218.

Vosoghi, S. , Zakerinejad, R. and entezari, M. (2025). Prediction of Gully Erosion and identifying factors affecting it using the Maximum Entropy Model and BCC-CSM2-MR climate change models for the years 2020-2040 (case study: Alamarvdasht watershed). *Journal of Geography and Planning*, *28*(90), 163-141. https://doi.org/10.22034/gp.2023.57572.3169 [In Persian]

Wassie, S. B. (2020). Natural resource degradation tendencies in Ethiopia: A review. *Environmental Systems Research*, 9(1), 1–29. https://doi.org/10.1186/s40068-020-00194-1

Zakerinejad, R. and Kahrani, A. (2025). Prediction of gully erosion and identifying its effective factors in the Khasuyeh watershed in Fars province. *Journal of Geography and Planning*, 30(95), 223-243. https://doi.org/10.22034/gp.2025.65173.3342 [In Persian]