



Publisher: Soil Science Society of Iran

Journal of Soil Research (Soil and Water Sci.)

<https://srjournal.areeo.ir/>


Spatial Modeling of Soil Erodibility Indices Using Machine Learning and Multi-Source Geospatial Data in the Sistan Plain

Abolfazl Bameri^a, Farhad Khormali^a , Farshad Kiani^a , Ali Shahriari^{b*} , and Mohammad Reza Pahlavan-Rad^c

^a Department of Soil Science, Faculty of Water and Soil Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran.

^b Department of Soil Science, Faculty of Water and Soil, University of Zabol, Zabol, Iran.

^c Soil and Water Research Department, Golestan Agricultural and Natural Resources Research and Education Center, AREEO, Gorgan, Iran.

Article Info

Article Type

Research Article

Received

May 31, 2026

Revised

July 31, 2026

Accepted

August 11, 2026

Published online

September 06, 2026

Keywords

Boruta Algorithm

Cubist

Digital Soil Mapping

Flood Plain

Random Forest

Soil Erosion

*Corresponding author's email

shahriari.ali@uoz.ac.ir

Extended Abstract

Background and Objectives: Soil erosion is currently recognized as a critical global challenge with severe social, economic, and environmental consequences. Accurate estimation of soil erodibility is a pivotal factor in the precise simulation of erosion processes and sustainable land management. In recent years, Digital Soil Mapping (DSM) coupled with Machine Learning (ML) algorithms has emerged as a powerful approach for handling complex environmental datasets. The primary objective of this study was to evaluate the influence of three groups of environmental covariates—soil properties, geomorphometric indices derived from a Digital Elevation Model (DEM), and multi-sensor remote sensing data (Landsat 8 and Sentinel-2)—on the spatial modeling of water erodibility (Factor K) and wind erodibility (Erodible Fraction - EF) in the Sistan Plain. Specifically, four widely used ML algorithms, including Regression Tree (rpart), Support Vector Machine (SVM), Cubist, and Random Forest (RF), were employed. Water erodibility (K) was calculated using three distinct equations: USLE, EPIC, and Sharpley and Smith, while wind erodibility was determined using the Fryrear method.

Materials and Methods: To achieve the research objectives, 1200 surface soil samples were collected from agricultural lands in the study area, and relevant physicochemical properties for the K factor and EF index were measured. Remote sensing variables were extracted from Landsat 8 (OLI sensor) and Sentinel-2 (MSI sensor) imagery. Landsat 8 data with a spatial resolution of 30 m were acquired from the United States Geological Survey (USGS) archive, while Sentinel-2 data (10, 20, and 60 m resolution) were obtained from the Copernicus Open Access Hub to enhance analysis accuracy. The dataset comprised six main spectral bands, four soil-related spectral indices (Clay, Carbonate, Salinity, and Gypsum), five vegetation indices (NDVI, EVI, PVI, RVI, SAVI), and one innovative index (KfactorRS Index). To mitigate the risk of overfitting and reduce dimensionality, the Boruta algorithm was implemented for precise feature selection for each target variable. Subsequently, the dataset was randomly split into training (80%) and testing (20%) subsets. The predictive performance and accuracy of the ML models were evaluated using seven statistical metrics: Mean Error (ME), Root Mean Square Error (RMSE), Normalized RMSE (NRMSE), Pearson correlation coefficient (r), Coefficient of Determination (R²), Ratio of Performance to Deviation (RPD), and Lin's Concordance Correlation Coefficient (CCC).

Results: The results indicated a significant negative correlation ($p < 0.01$) between water erodibility coefficients (K) and the wind erodibility index (EF). A justifiable behavioral pattern observed in this study was the emergence of a negative correlation between spectral vegetation indices and clay content; a phenomenon that, contrary to initial assumptions, stems from vegetation degradation driven by salinity accumulation in fine-grained soils. Furthermore, the unexpected direct relationships of the K_{EPIC} and K_{ShSm} equations with organic carbon, and clay, alongside an inverse relationship with very fine sand, indicate a high sensitivity to textural variables that

introduces statistical bias under the region's specific conditions. Consequently, applying these indices is not recommended without recalibration tailored to the local geomorphic setting. Regarding model performance, the Cubist algorithm demonstrated superior predictive capability for most variables (EF, K_{EPIC} , K_{ShSm}), while the Random Forest (RF) model outperformed others in predicting K_{USLE} . Both Cubist and RF, as ensemble-based decision tree methods, showed high competence in modeling soil erosion complexities. Although the SVM model yielded reasonable performance across all variables, it never ranked as the superior model. Conversely, the rpart model exhibited the weakest performance, particularly for K_{EPIC} and K_{ShSm} , indicating the inability of simple single-tree models to capture the non-linear complexities of soil erosion in this region.

Conclusion: Although Random Forest is widely recognized as one of the most proven and practical algorithms in DSM, this study demonstrated that rule-based models such as Cubist—which offer greater flexibility in modeling local non-linear relationships—can outperform RF in specific scenarios. Nevertheless, the consistency and stability of RF across all variables (consistently ranking first or second) and its absence of poor performance establish it as a safe and robust choice for predicting soil properties and erosion parameters in digital soil mapping studies.

Cite this article: Bameri, A., Khormali, F., Kiani, F., Shahriari, A., Pahlavan-Rad, M.R., 2026. Spatial Modeling of Soil Erodibility Indices Using Machine Learning and Multi-Source Geospatial Data in the Sistan Plain. Research Article, *Journal of Soil Research*, 40 (2), pp 235-261.



DOI: <https://doi.org/10.22092/IJSR.2026.372940.820>

Publisher: Soil Science Society of Iran

مقدمه

فرسایش خاک به عنوان یکی از عوامل اصلی تخریب اراضی، تأثیرات مخربی بر مدیریت پایدار زیست‌بوم‌ها دارد. برآوردهای جهانی نشان می‌دهد فرسایش آبی سالانه حدود ۳۵/۹ میلیارد تن خاک را جابه‌جا می‌کند (Borrelli et al., 2017; Han et al., 2023) و فرسایش بادی نیز سهم قابل توجهی در تخریب اراضی مناطق خشک و نیمه‌خشک دارد (Fenta et al., 2019). این پدیده امروزه یک چالش بزرگ اجتماعی، اقتصادی و محیط‌زیستی است که توسعه پایدار را تهدید می‌کند (Barbut & Alexander, 2016).

فرسایش خاک در ابتدا حاصلخیزی اراضی و کیفیت خاک را کاهش می‌دهد (Kanianska et al., 2024) و به تدریج و بدون کنترل آن منجر به کاهش بهره‌وری اراضی (Jafari et al., 2022)، کاهش کیفیت هوا (Gholami et al., 2021) و منابع آب (Kjelland et al., 2015)، کاهش تنوع زیستی (Guerra et al., 2020) و افزایش خطر سیلاب (Jafari et al., 2022) می‌گردد که پایداری سیستم‌های اجتماعی-اکولوژیکی را به خطر می‌اندازد.

در کشورهای خشک و نیمه‌خشک مانند ایران، محدودیت پوشش گیاهی و بهره‌برداری نامتناسب از اراضی، پیامدهای فرسایش را تشدید کرده است. مطالعات نشان می‌دهد بخش‌های وسیعی از کشور تحت تأثیر فرسایش آبی (به‌ویژه در مناطق شیب‌دار) و فرسایش بادی (به‌ویژه در نواحی بادخیز شرق نظیر دشت سیستان) قرار دارند (Asadi et al., 2022; Rahmati et al., 2025). این شرایط، پایش و مدل‌سازی مکانی فرسایش را برای برنامه‌ریزی‌های حفاظتی ضروری ساخته است. در این راستا، درک عمیق فرآیندهای فرسایش نیازمند توجه ویژه به مفهوم فرسایش‌پذیری خاک است. فرسایش‌پذیری، ویژگی ذاتی خاک است که حساسیت ذرات آن را، به جدا شدن و انتقال توسط عوامل فرساینده (آب و باد) نشان می‌دهد و تابعی پیچیده از ویژگی‌های فیزیکی و مکانیکی خاک نظیر توزیع اندازه ذرات، ساختار خاک، پایداری خاکدانه‌ها، نفوذپذیری و محتوای ماده آلی است (Jafari et al., 2022). این ویژگی رفتار مکانیکی خاک را در برابر انرژی آب یا تنش برشی باد تعیین می‌کند. همچنین، Tian و همکاران (۲۰۲۲) و Sun و همکاران (۲۰۲۴) تأکید دارند که یکی از مهم‌ترین و بنیادی‌ترین عوامل در ارزیابی دقیق فرسایش خاک، تعیین مقدار فرسایش‌پذیری آن است. مطالعات داخلی متعددی به بررسی این مفهوم و کاربرد معادلات تجربی برآورد

فرسایش‌پذیری (مانند ضرایب K در فرسایش آبی و EF در فرسایش بادی) در حوضه‌های مختلف کشور پرداخته‌اند که نشان‌دهنده اهمیت این شاخص در ارزیابی و مدیریت منابع خاک ایران است (Ouri et al., 2020; Khosravi et al., 2023; Rezaei et al., 2023; Torkamani et al., 2026). این پژوهش‌ها تأکید می‌کنند که تنوع شدید لیتولوژی و شرایط اقلیمی در ایران، منجر به تغییرات مکانی و زمانی قابل توجهی در حساسیت ذرات خاک به فرسایش شده و ارزیابی دقیق فرسایش‌پذیری را به یک چالش پیچیده در مدیریت حفاظت خاک تبدیل کرده است. افزون بر این، مطالعات یادشده، اهمیت استفاده از شاخص‌های فرسایش‌پذیری را در شناسایی مناطق بحرانی، اولویت‌بندی عملیات حفاظت خاک و مدیریت حوضه‌های آبخیز ایران برجسته می‌سازد. با این حال، بخش عمده این پژوهش‌ها بر فرسایش آبی یا ضریب K متمرکز بوده‌اند و مدل‌سازی هم‌زمان و مقایسه‌ای شاخص‌های فرسایش‌پذیری آبی و بادی، به ویژه در دشت‌های خشک، کم ارتفاع و نسبتاً هموار، کمتر مورد توجه قرار گرفته است.

برای کمّی‌سازی این مفهوم، در مدل‌های برآورد فرسایش، این عامل در قالب متغیرهای عددی خاص هر مدل نظیر ضریب K در معادله جهانی هدر رفت خاک (USLE^۱) یا ضریب EF در معادله بازنگری‌شده فرسایش بادی (RWEQ^۲) تبلور می‌یابد. این ضرایب در اصل باید از طریق واسنجی مدل و بر مبنای داده‌های میدانی اندازه‌گیری شده هدر رفت خاک (مانند کرت‌های استاندارد یا تونل باد) تعیین شوند. از آنجا که واسنجی مستقیم این ضرایب پرهزینه است، معمولاً از توابع انتقالی و روابط تجربی مبتنی بر ویژگی‌های خاک استفاده می‌شود (Abiye & Dengiz, 2025). با توجه به دشواری اندازه‌گیری‌های وسیع میدانی، نقشه‌برداری رقومی خاک^۳ (DSM) با بهره‌گیری از سنجنش از دور و الگوریتم‌های یادگیری ماشین، به عنوان چارچوبی نوین برای پیش‌بینی پراکنش مکانی ویژگی‌های خاک توسعه یافته است (Rezaei et al., 2023). در این چارچوب، خروجی‌های مکانی این مدل‌ها، علاوه بر تأمین داده‌های ورودی، امکان مدل‌سازی مستقیم و تهیه نقشه‌های پیوسته ضرایب فرسایش‌پذیری مدل‌ها را در مقیاس‌های منطقه‌ای فراهم می‌سازند (McBratney et al., 2003). با این وجود، باید توجه داشت که جایگزینی داده‌های اندازه‌گیری شده هدر رفت خاک (در کرت‌های استاندارد) با برآوردهای حاصل از معادلات تجربی ثانویه و سپس تعمیم مکانی آن‌ها با استفاده از متغیرهای محیطی، ذاتاً با سطحی از

³ Soil Digital Mapping¹ Universal Soil Loss Equation² Revised Wind Erosion Equation

مناطق پرشیب در این دشت قابل تعمیم نبوده و نیازمند اعتبارسنجی است.

در پاسخ به این شکاف علمی، پژوهش حاضر با هدف ارزیابی توانایی متغیرهای محیطی (خصوصیات خاک، شاخص‌های ژئومورفومتریک و داده‌های ماهواره‌ای لندست ۸ و سنتینل ۲) در مدل‌سازی مکانی شاخص‌های K و EF طراحی شد. بدین منظور، چهار الگوریتم یادگیری ماشین (درخت رگرسیون، ماشین بردار پشتیبان، کیویست و جنگل تصادفی) به کار گرفته شدند. همچنین، کارایی سه معادله تجربی برآورد ضریب فرسایش‌پذیری آبی (K_{ShSm} و K_{EPIC} و K_{USLE}) در شرایط خاص این دشت ارزیابی گردید تا گامی مؤثر در توسعه روش‌های نقشه‌برداری رقومی در مناطق کم‌ارتفاع و همگن برداشته شود.

مواد و روش‌ها

منطقه مورد مطالعه و وضعیت فرسایش خاک

منطقه مورد مطالعه، بخشی از اراضی کشاورزی دشت سیستان واقع در شرق دریاچه هامون با مساحتی حدود ۲۰۱ هزار هکتار است که بین مختصات جغرافیایی $۶۱^{\circ} ۱۰'$ تا $۶۱^{\circ} ۴۵'$ شرقی و $۳۰^{\circ} ۵۰'$ تا $۳۱^{\circ} ۲۲'$ شمالی قرار دارد (شکل ۱). ارتفاع متوسط منطقه از سطح دریا ۴۸۵ متر، میانگین بارندگی سالانه ۵۵ میلی‌متر و تبخیر و تعرق سالانه ۴۵۰۰ تا ۵۰۰۰ میلی‌متر است. کاربری اراضی عمدتاً شامل کشاورزی، مرتع و اراضی رها شده است. رژیم رطوبتی و حرارتی خاک‌های منطقه به ترتیب اریدیک و هایپرترمیک بوده و خاک‌های آن که از رسوبات آبرفتی هیرمند تشکیل شده‌اند، از نظر تکاملی جوان محسوب می‌شوند (Mirakzehi et al., 2018). کاربری اراضی عمدتاً شامل کشاورزی، مرتع و اراضی رها شده است.

دشت سیستان به دلیل اقلیم فراخشک و وزش بادهای شدید ۱۲۰ روزه، یکی از باد خیزترین مناطق ایران است و فرسایش بادی فرآیند غالب تخریب خاک در آن محسوب می‌شود. بافت سبک تا متوسط خاک، شوری، رطوبت سطحی پایین و حضور تپه‌های ماسه‌ای، آستانه حرکت ذرات را کاهش داده و شرایط را برای فرسایش بادی گسترده، تولید گردوغبار و تضعیف ساختار و ماده آلی خاک فراهم کرده است (Nourafar et al., 2022).

در کنار فرسایش بادی، منطقه تحت تأثیر فرسایش آبی موضعی نیز قرار دارد. در بخش‌هایی از اراضی کشاورزی و مرتعی، به‌ویژه مناطقی

عدم قطعیت و انتشار خطا^۱ همراه است. در این ارتباط Abiye و Dengiz (۲۰۲۵) تأکید می‌کنند که اگرچه ترکیب روش‌های سنجش از دور، داده‌های توپوگرافی و چارچوب DSM می‌تواند در تهیه نقشه‌های مکانی خطر فرسایش مفید باشد و به درک الگوی مکانی عوامل مرتبط با ضریب فرسایش‌پذیری مدل‌ها کمک کند، اما باید در نظر داشت که این تحلیل‌ها، مبتنی بر برآوردهای مدل و فاقد داده‌های اندازه‌گیری شده هدر رفت خاک هستند و بنابراین با سطحی از عدم قطعیت همراه‌اند. در همین راستا، روش‌های یادگیری ماشین از جمله ماشین بردار پشتیبان (Abiye & Dengiz, 2025)، درخت تصمیم (Ghosh & Maiti, 2021)، کیویست (Sun et al., 2024) و جنگل تصادفی (Ghosh & Maiti, 2021; Tian et al., 2024; Abiye & Dengiz, 2025) به عنوان روش‌های متداول در نقشه‌برداری رقومی خاک، به طور گسترده برای مدل‌سازی و تولید نقشه‌های توزیع مکانی فرسایش‌پذیری خاک مورد استفاده قرار گرفته‌اند (Sun et al., 2024).


دشت سیستان به‌عنوان یک دشت سیلابی با خاک‌های ریزبافت و ساختار ضعیف، با تهدید دوگانه فرسایش آبی و بادی مواجه است که فرسایش‌پذیری ذاتی آن را به شدت افزایش داده است. برای حفاظت از منابع خاک این منطقه، پیش‌بینی مکانی دقیق شاخص‌های K و EF امری حیاتی است. با این وجود، بیشتر پژوهش‌های پیشین نقشه‌برداری رقومی در مناطق کوهستانی با توپوگرافی برجسته انجام شده‌اند (Ouri et al., 2020; Rezaei et al., 2023; Khosravi et al., 2023; Sun et al., 2024; Parajuli et al., 2025). در دشت مسطح سیستان، تضعیف سیگنال‌های ژئومورفومتریک سبب می‌شود کارایی مدل‌های پیشین نیازمند بازنگری باشد.

مرور ادبیات علمی مرتبط با نقشه‌برداری رقومی فرسایش‌پذیری خاک نشان می‌دهد که بخش عمده پژوهش‌های پیشین در مناطقی با توپوگرافی برجسته و اختلاف ارتفاعی قابل توجه انجام شده‌اند، جایی که نقش شاخص‌های ژئومورفومتریک در کنترل تغییرات مکانی فرسایش‌پذیری خاک، به‌ویژه فرسایش آبی، بسیار پررنگ و قابل مدل‌سازی است (Ouri et al., 2020; Rezaei et al., 2023; Khosravi et al., 2023; Sun et al., 2024; Parajuli et al., 2025). برخلاف مناطق کوهستانی، دشت کم‌ارتفاع سیستان (اختلاف ارتفاع حدود ۶۰ متر) توپوگرافی همگنی دارد که سیگنال‌های ژئومورفومتریک را تضعیف و نقش عواملی چون بافت خاک و پوشش سطحی را پررنگ می‌کند. لذا کارایی روش‌های

¹ Error Propagation

این شرایط نشان می‌دهد که دشت سیستان یک سامانه فرسایشی مرکب است که در آن فرسایش بادی غالب بوده و فرسایش آبی سطحی نیز به‌طور موضعی کارکرد خاک را تهدید می‌کند. این موضوع، ضرورت مدل‌سازی مکانی حساسیت ذاتی خاک و ارزیابی دقیق شاخص‌های K (نماینده فرسایش‌پذیری آبی سطحی) و EF (نماینده فرسایش‌پذیری بادی) را در این منطقه برجسته می‌سازد.

که ساختمان خاک در اثر تردد ماشین‌آلات یا چرای دام‌های سنگین (مانند گاو سیستانی و شتر) دچار فشردگی و کاهش نفوذپذیری شده است، جریان‌های سطحی کم‌عمق و پخشایی منجر به وقوع فرسایش ورقه‌ای و شیاری می‌شوند. هرچند به‌دلیل توپوگرافی هموار دشت، شدت فرسایش آبی نسبت به مناطق کوهستانی کمتر است، اما ترکیب آن با فرسایش بادی در اراضی با مدیریت نامناسب، حاصلخیزی خاک را به‌شدت کاهش داده و بیابان‌زایی را تشدید می‌کند.



شکل ۱- موقعیت جغرافیایی نقاط نمونه‌برداری در سطح دشت سیستان.
Figure 1. Geographical location of sampling points on the Sistan Plain.

منطقه‌ای و امکان مقایسه مکانی نمونه‌ها در نظر گرفته شده است؛ زیرا لایه سطحی بیشترین تماس را با عوامل فرساینده داشته و ویژگی‌های مؤثر بر فرسایش‌پذیری عمدتاً در این بخش نمود می‌یابند. در آزمایشگاه، همه نمونه‌ها در هوا خشک، خرد و از الک ۲ میلی‌متری (شماره ۱۰) عبور داده شدند. ویژگی‌های درصد اجزای بافت خاک (شن، سیلت و رس) به روش هیدرومتر (Wang et al., 2016)، شن خیلی ریز به روش پیپت (Olmstead et al., 2016)

شاخص‌های فرسایش پذیری

با استفاده از نرم‌افزار ArcGIS نسخه ۱۰/۸، حدود ۱۲۰۰ نقطه به‌صورت تصادفی در واحدهای اجزاء اراضی غالب دشت سیستان انتخاب شد. در هر نقطه، نمونه‌های خاک از لایه سطحی، یعنی عمق ۰ تا ۳۰ سانتی‌متر، جمع‌آوری شدند. این عمق با هدف بررسی افق‌های ژنتیکی خاک انتخاب نشده، بلکه به‌منظور دستیابی به نماینده‌ای یکنواخت از خاک سطحی در مقیاس

در رابطه (۲ و ۳)، SAN درصد شن، SIL درصد سیلت، CLA درصد رس، C درصد کربن آلی و $SN1 = 1 - SAN/100$ می‌باشند. لازم به ذکر هست که مقدار K محاسبه شده در این سه معادله در واحدهای مرسوم ایالات متحده آمریکا است که می‌توان آن را با ضرب کردن در 0.1317 به واحدهای متریک SI^1 یعنی $tn\ ha\ h\ ha^{-1}$ هکتار در ساعت بر هکتار در مگاژول در میلی‌متر ($t\ ha\ h\ ha^{-1}$) تبدیل کرد (Sun et al., 2024).

رابطه (۴)

$$EF = 29.09 + 0.31 Sa + 0.17 Si + [0.33 \times (Sa/Cl)] - 2.59 OM - 0.95 Ca$$

روش RWQE که در آن EF بخش فرسایش‌پذیری بادی فرمولی خاک، Sa شن، Si سیلت، Cl رس، OM ماده آلی و Ca کربنات کلسیم است و تمامی متغیرها به درصد می‌باشند (Fryrear et al., 1998).

پس از محاسبه مقادیر فرسایش‌پذیری آبی و بادی، فرآیند تجزیه و تحلیل داده‌ها صورت پذیرفت. در مرحله نخست، شاخص‌های آمار توصیفی (میانگین، انحراف معیار، حداقل، حداکثر و...) برای هر متغیر محاسبه شد. سپس مقادیر پرت شناسایی و از مجموعه داده‌های هدف حذف گردید تا از تأثیر آن‌ها بر تحلیل‌های بعدی جلوگیری شود.

تشخیص و حذف داده‌های پرت

برای افزایش قابلیت اطمینان داده‌ها و کاهش تأثیر مقادیر شدید داده‌ها، یک روش تشخیص داده‌های پرت، مبتنی بر نمودار جعبه‌ای با استفاده از معیار دامنه بین چارکی^۲ (IQR) اعمال شد. به طور خاص، مقادیری که کمتر از $Q_1 - 1.5 \times IQR$ یا بالاتر از $Q_3 + 1.5 \times IQR$ قرار داشتند، به عنوان داده‌های پرت در نظر گرفته شده و از تجزیه و تحلیل بیشتر حذف شدند؛ که در آن Q_1 و Q_3 به ترتیب نشان دهنده چارک اول و سوم و IQR محدوده بین چارکی است (Mazarei et al., 2025). این رویکرد به صورت متوالی برای هر دو متغیر شاخص EF و شاخص K در R با استفاده از تابع $\text{boxplot}()$ پیاده‌سازی شد که به طور خودکار مقادیر پرت را شناسایی و استخراج می‌کند.

(1930)، درصد کربنات کلسیم معادل به روش تیتراسیون (Sparks et al., 1996)، pH خاک در گل اشباع، قابلیت هدایت الکتریکی در عصاره اشباع (Husson et al., 2018) و کربن آلی با اکسیداسیون تو سطر دی کرومات پتا سیم (Sparks et al., 1996) نمونه‌ها اندازه‌گیری شد.

با بهره‌گیری از داده‌های حاصل از آزمایش‌های آزمایشگاهی و مشاهدات صحرایی (تعیین وضعیت ساختمان خاک)، ضریب فرسایش‌پذیری آبی USLE (K) براساس سه مدل USLE (Williams et al., 1978)، EPIC (Wischmeier & Smith, 1978) و روش شارپلی و اسمیت (Sharpley & Smith, 1990) و فرسایش‌پذیری بادی EF با استفاده از مدل RWQE (Fryrear et al., 1998) در نمونه‌ها محاسبه شد.

رابطه (۱)

$$K_{USLE} = [(2.1 \times 10^{-4} \times M^{1.14} \times (12 - OM) + 3.25 (S - 2) + 2.5 (P - 3)) / 100]$$

روش USLE که در معادله آن K ضریب (شاخص) فرسایش‌پذیری خاک (تن در هکتار در ساعت بر هکتار در مگاژول در میلی‌متر) است. در این معادله M از حاصل ضرب (درصد رس - ۱۰۰) در (درصد سیلت + درصد شن خیلی ریز) به دست می‌آید، OM درصد ماده آلی خاک، S کلاس ساختمان خاکدانه و P کلاس نفوذپذیری خاک است. براساس اصلاحیه Auerswald و همکاران (۲۰۱۴) و (۲۰۱۶) برای خاک‌هایی با مقادیر بالای سیلت و شن خیلی ریز (بیش از ۷۰ درصد) برآورد شاخص فرسایش‌پذیری آبی (K) انجام پذیرفت. کلاس ساختمان خاک (S) در صحرا و در زمان نمونه‌برداری ارزیابی شد و کلاس نفوذپذیری (P) نیز با استفاده از بافت خاک، براساس جدول استاندارد ارائه شده توسط Fenta و همکاران (۲۰۲۰) تعیین گردید.

رابطه (۲)

$$K_{EPIC} = \{0.2 + 0.3 \exp[-0.0256SAN(1 - SIL/100)]\} [SIL/(CLA + SIL)]^{0.3} [1 - (0.25C / (C + \exp(3.72 - 2.95C)))] [1 - (0.7SN_1 / (SN_1 + \exp(-5.51 + 22.9 SN_1)))]$$

روش EPIC

رابطه (۳)

$$K_{ShSm} = \{0.2 + \exp[0.0256SAN(1SIL/100)]\} [SIL/(CLA + SIL)]^{0.3} [1 - (0.25C / (C + \exp(3.72 - 2.95C)))] [1 - (0.7SN_1 / (SN_1 + \exp(-5.51 + 22.9 SN_1)))]$$

روش شارپلی و اسمیت

² Interquartile Range

¹ International System

10.8 و SAGA GIS 9.2، مجموعاً ۴۱ متغیر ژئومورفومتریک شامل مشتقات درجه اول و دوم DEM (مانند شیب، جهت شیب، انحنای پروفیل و پلان، شاخص رطوبت توپوگرافیک و...) محاسبه گردید. لیست کامل این متغیرها در (جدول ۱) ارائه شده است.

متغیرهای محیطی پیش‌بین در مدل‌سازی

در این پژوهش، برای پیش‌بینی متغیر هدف (فرسایش‌پذیری خاک)، از مجموعه‌ای از متغیرهای محیطی به عنوان ورودی‌های مدل جنگل تصادفی استفاده شد. این متغیرها به سه گروه اصلی تقسیم می‌شوند: ۱) متغیرهای خاک، ۲) متغیرهای ژئومورفومتریک مشتق از مدل رقومی ارتفاع (DEM) و ۳) متغیرهای سنجش از دوری شامل شاخص‌های طیفی گیاه و خاک.

متغیرهای خاک

انتخاب متغیرهای خاک با یک ملاحظه روش‌شناختی کلیدی انجام شد. هدف این امر، جلوگیری از ایجاد یک رابطه ساختگی یا استدلال دوری^۱ در مدل بود. از آنجا که متغیرهایی مانند درصد سیلت، رس و مواد آلی مستقیماً در فرمول‌های محاسباتی ضرایب فرسایش‌پذیری آبی (K) و بادی (EF) به کار می‌روند، ورود آن‌ها به عنوان متغیر پیش‌بین می‌توانست باعث شود مدل جنگل تصادفی صرفاً رابطه ریاضی موجود در فرمول را بازتولید کند و از شناسایی سایر روابط پیچیده و پنهان باز بماند. برای رفع این مشکل، متغیرهایی انتخاب شدند که در فرمول محاسباتی این ضرایب نقشی ندارند. بر این اساس برای پیش‌بینی ضریب فرسایش‌پذیری آبی (K) از داده‌های کربنات کلسیم معادل (CCE)، اسیدیته (pH) و شوری (EC) خاک استفاده شد. برای پیش‌بینی ضریب فرسایش‌پذیری بادی (EF)، از متغیرهای شن خیلی ریز (Vfsand)، اسیدیته (pH) و شوری خاک (EC) به عنوان متغیرهای ورودی بهره گرفته شد.

متغیرهای ژئومورفومتریک

با توجه به طبیعت نسبتاً هموار و کم ارتفاع منطقه مطالعاتی، دقت بالای داده‌های توپوگرافی برای شناسایی تفاوت‌های ظریف لندفرم ضروری بود. از این رو، متغیرهای ژئومورفومتریک از مدل رقومی ارتفاع (DEM) ماهواره ALOS PALSAR با تفکیک مکانی ۱۲/۵ متر (<https://asf.alaska.edu>) استخراج شدند. پیش‌پردازش DEM شامل عملیات پر کردن چاله‌ها^۲ با استفاده از ابزار Fill در نرم‌افزار ArcGIS 10.8 بود تا از ایجاد خطاهای هیدرولوژیکی در استخراج متغیرها جلوگیری شود (Planchon & Darboux, 2001). سپس با بهره‌گیری از نرم‌افزارهای ArcGIS

² Sink Fill

¹ Circular Reasoning

جدول ۱- متغیرهای ژئومورفومتریک استخراج شده از DEM و مورد استفاده در مدل‌سازی.

Table 1. Geomorphometric variables extracted from DEM and used in modeling.

متغیرها	مخفف	متغیرها	مخفف
Parameters	Abbreviation	Parameters	Abbreviation
Analytical Hillshading	AH	Maximal Curvature	MxC
سایه‌روشن تحلیلی		انحنای حداکثر	
Aspect	ASP	Minimal Curvature	MnC
جهت شیب		انحنای حداقل	
Catchment Area	CTA	Modified Catchment Area	MCA
مساحت حوضه آبریز		مساحت حوضه اصلاح شده	
Catchment Slope	CTS	Multi-resolution Ridge TopFlatness	MRRTF
شیب حوضه آبریز		مسطح بودن بال (چند مقیاسی)	
Channel Network Base Level	CNBL	Multi-resolution ValleyBottom Flatness	MRVBF
تراز پایه شبکه آبراهه		مسطح بودن کف دره (چند مقیاسی)	
Channel Network Distance	CND	Plan Curvature	PIC
فاصله از شبکه آبراهه		انحنای افقی	
Closed Depressions	CD	Profile Curvature	PrC
فرورفتگی‌های بسته		انحنای عمودی	
Convergence Index	CI	Relative Slope Position	RSP
شاخص همگرایی جریان		موقعیت نسبی شیب	
Cross Sectional Curvature	CSC	Saga Wetness Index	SWI
انحنای مقطع عرضی		شاخص رطوبت ساگا	
Curvature	Cr	Slope	Slp
انحنا		شیب	
Downslope Curvature	DC	Tangential Curvature	TanC
انحنای پایین‌دست		انحنای مماسی	
Elevation	Elv	Terrain Ruggedness Index	TRI
ارتفاع		شاخص ناهمواری زمین	
Flow direction	FD	Terrain Surface Texture	TST
جهت جریان		بافت سطح زمین	
Flow Line Curvature	FLC	Topographic Position Index	TPI
انحنای خط جریان		شاخص موقعیت توپوگرافیک	
General Curvature	GC	Topographic Wetness Index	TWI
انحنای عمومی		شاخص رطوبت توپوگرافیک	
HillShade	Hi	Total Catchment Area	TCA
سایه روشن		مساحت کل حوضه آبریز	
Local Curvature	LC	Total Curvature	TC
انحنای محلی		انحنای کل	
Local Downslope Curvature	LDC	Upslope Curvature	UpC
انحنای محلی پایین‌دست		انحنای بالادست	
Local Upslope Curvature	LUC	Valley Depth	VD
انحنای محلی بالادست		عمق دره	
Longitudinal Curvature	LgC	Wind Effect	WE
انحنای طولی		اثر باد	
LS Factor	LS		
عامل طول-شیب (LS)			

متغیرهای سنجش از دوری

دارای باندهای طیفی با قدرت تفکیک مکانی بالاتر (۱۰، ۲۰ و ۶۰ متر) هستند و از پورتال Copernicus Open Access Hub (<https://scihub.copernicus.eu>) دریافت شدند، نیز استفاده شد. پیش از استخراج شاخص‌ها، تصحیحات رادیومتریک و اتمسفری با استفاده از الگوریتم FLAASH در نرم‌افزار ENVI 5.6 بر روی کلیه تصاویر اعمال گردید (Lucieer et al., 2014). در خصوص تصاویر سنتینل-۲، محصول سطح بازتابی (Level-2A) مورد استفاده قرار

در این پژوهش، متغیرهای سنجش از دوری از تصاویر ماهواره Landsat 8 سنجنده OLI و همچنین تصاویر ماهواره Sentinel-2 سنجنده MSI استخراج شدند. تصاویر لندست ۸ با قدرت تفکیک مکانی ۳۰ متر از پایگاه داده سازمان زمین‌شناسی ایالات متحده آمریکا (<https://earthexplorer.usgs.gov>) دریافت گردیدند. به منظور بهبود دقت تحلیل‌ها، از داده‌های سنتینل-۲ که

شاخص طیفی مرتبط با خاک و سطح زمین (شامل شاخص رس، شاخص کربنات، شاخص شوری و شاخص گچ)، پنج شاخص پوشش گیاهی (NDVI, EVI, PVI, RVI, SAVI) و یک شاخص ابدایی ($Kfactor_{RS}$ Index) که بر اساس تحلیل همبستگی بین باندهای طیفی و ضرایب فرسایش‌پذیری طراحی شد، می‌باشند. لیست کامل شاخص‌ها و فرمول محاسباتی آن‌ها، در (جدول ۲) آمده است.

گرفت که پیش از این با در نظر گرفتن اصلاحات اتمسفری و حذف اثرات ابر و پیکسل‌های معیوب پردازش شده بود و مستقیماً برای استخراج شاخص‌ها مناسب بود.

متغیرهای مورد استفاده شامل شش باند مشترک و اصلی طیفی سنجنده‌های OLI و MSI (شامل سه باند مرئی: آبی، سبز و قرمز و سه باند مادون قرمز: NIR، SWIR1 و SWIR2)، چهار

جدول ۲- شاخص‌های سنجنش از دوری استخراج شده از تصاویر لندست ۸ و سنتینل ۲ و مورد استفاده در مدل‌سازی.

Table 2. Remote sensing indices extracted from Landsat 8 and Sentinel-2 images and used in modeling.

شاخص Indices	تعریف Definition	منبع Reference	شاخص Indices	تعریف Definition	منبع Reference
Blue	0.452–0.51 μm	Band 2	EVI	$2.5 \times (\text{NIR} - \text{Red}) / (\text{NIR} + 6 \times \text{Red} - 7.5 \times \text{Blue}) + 1$	Huete et al. (1997)
Green	0.53–0.59 μm	Band 3	Gypsum Index	$(\text{SWIR1} - \text{NIR}) / (\text{SWIR1} + \text{NIR})$	Taghizadeh-Mehrjardi et al (2014)
Red	0.64–0.67 μm	Band 4	$Kfactor_{RS}$ Index	$(\text{Red} - \text{Green}) / (\text{NIR} / \text{Blue})$	Authors
NIR	0.85–0.88 μm	Band 5 L-Band 8 S	NDVI	$(\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red})$	Huete et al. (1997)
SWIR1	1.57–1.65 μm	Band 6 L-Band 11 S	PVI	$(\text{NIR} - a * \text{Red} - b) / (1 + a^2)^{1/2}$	Richardson & Weigand (1977)
SWIR2	2.11–2.29 μm	Band 7 L-Band 12 S	RVI	NIR / Red	Pearson & Miller, (1972)
CCE Index	Red/Green	Taghizadeh-Mehrjardi et al (2014)	Salinity Ratio	$(\text{Red} - \text{NIR}) / (\text{Green} + \text{NIR})$	Taghizadeh-Mehrjardi et al (2014)
Clay Index	$\text{SWIR1} / \text{SWIR2}$	Taghizadeh-Mehrjardi et al (2014)	SAVI	$[(\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red} * \text{L})] * (1 + \text{L})$	Huete (1988)

*حرف L نشان‌دهنده تصاویر لندست ۸ و حرف S نشان‌دهنده تصاویر سنتینل ۲ است.

*The letter L represents Landsat 8 images and the letter S represents Sentinel 2 images.

سری داده‌های آزمون صورت گرفت. توانایی و دقت هر مدل بر اساس هفت معیار ارزیابی شد: ۱) میانگین خطا (ME)، مجذور میانگین مربعات خطا (RMSE) (Bameri et al., 2015)، NRMSE (Otto et al., 2018)، همبستگی پیرسون (r)، ضریب تبیین (R^2)، نسبت عملکرد به انحراف (RPD) و ضریب تطابق لین (CCC) (Zeraatpisheh et al., 2025) در هر دو مجموعه داده مورد ارزیابی قرار گرفت. در نهایت بهترین مدل براساس مقایسه عملکرد مدل‌ها در مرحله آزمون معرفی گردید.

معیارهای اعتبارسنجی نشان داد که مدل‌هایی با ME، RMSE و NRMSE کمتر و مقادیر r ، R^2 ، RPD و CCC بالاتر، پیش‌بینی‌های دقیق‌تری دارند. ME، RMSE و NRMSE برای تشخیص تغییرات خطای پیش‌بینی مفید هستند. علاوه بر این، RPD میزان بهبود حاصل شده در فرآیند مدل‌سازی را ارزیابی می‌کند و مقادیر آن به سه کلاس پیش‌بینی طبقه‌بندی شد: عالی

اعتبارسنجی مدل

ابتدا برای کاهش خطر بیش برآزش و کاهش ابعاد فضای متغیرهای کمکی محیطی، یک روش انتخاب ویژگی دقیق با استفاده از الگوریتم بوروتا^۱ برای هر متغیر انجام شد (Kursa & Rudnicki, 2010). سپس به منظور ارزیابی دقت الگوریتم‌های یادگیری ماشین در پیش‌بینی فرسایش‌پذیری خاک، منتخب مجموعه داده‌های نقطه‌ای به صورت تصادفی به دو زیرمجموعه تقسیم شدند: ۸۰ درصد برای آموزش مدل و ۲۰ درصد برای آزمون و ارزیابی عملکرد مدل. سپس، مدل‌سازی مقادیر فرسایش‌پذیری خاک با استفاده از داده‌های آموزشی و الگوریتم مذکور صورت پذیرفت (جزئیات معرفی مدل‌های اجرا شده در منبع McBratney, 2003 ارائه شده است). در فاز آموزش، جهت تضمین پایداری مدل، از روش اعتبارسنجی تقاطعی^۲ با ۱۰ تکرار بهره برده شد. در نهایت، بر اساس ساختار بهینه حاصل از مرحله آموزش، پیش‌بینی فرسایش‌پذیری خاک بر روی

² k-fold

¹ Boruta


شده است. بر این اساس، مقادیر چولگی برای همه متغیرها بین $-۰,۴۵$ و $+۰,۴۴$ متغیر بود. در بررسی ضریب تغییرات، نتایج نشان داد که متغیرهای K_{USLE} و K_{ShSm} تغییرپذیری متوسطی ($CV \approx 22-24\%$) دارند، در حالی که K_{EPIC} تغییرپذیری کم تا متوسطی را نشان داد، به طوری که فرآیند اصلاح داده‌ها، CV آن را به زیر ۱۵ درصد کاهش داد. همچنین شاخص EF در محدوده تغییرپذیری متوسط قرار گرفت. ($CV \approx 17-18\%$) علاوه بر این، بررسی مقادیر نشان داد که کاهش مداوم CV پس از اصلاح در تمام متغیرها رخ داده است که حاکی از افزایش پایداری داده‌ها است.

($RPD > 2.0$)، معقول ($1.4 \leq RPD \leq 2$) و ضعیف ($RPD < 1.4$) (Zeraatpisheh et al., 2025).

نتایج

آمار توصیفی و بررسی داده‌ها

قبل از اقدام به مدل‌سازی، داده‌های اندازه‌گیری شده ضرایب فرسایش پذیری مورد کنترل و بازبینی قرار گرفت و داده‌های پرت و ناهمگن بر اساس نمودار جعبه‌ای توکی حذف گردیدند (شکل ۲). خلاصه‌ای از نتایج آمار توصیفی شاخص‌های K و EF در دو حالت داده خام و پالایش‌شده در (جدول ۳) ارائه



شکل ۱- نمودار جعبه‌ای ضرایب فرسایش پذیری شامل داده‌های خام و پالایش شده.

Figure 1. Boxplot of erodibility coefficients including raw and refined data.

جدول ۳- توصیف آماری شاخص‌های فرسایش پذیری در منطقه مورد مطالعه.

Table 3- Statistical description of erodibility indices in the study area.

متغیر Variable	نوع داده Data Type	حداقل Min	حداکثر Max	میانگین Mean	انحراف معیار Standard Deviation	میان Median	چولگی Skewness	کشیدگی Kurtosis	ضریب تغییرات CV (%)
K _{USLE}	خام Raw	0.01693	0.12012	0.0608	0.0142	0.0609	-0.0327	0.1148	23.4424
	پالایش شده Refined	0.0232	0.0985	0.0611	0.0134	0.0612	-0.0703	-0.2864	21.9319
K _{EPIC}	خام Raw	0.01641	0.06226	0.0440	0.0071	0.044591	-0.4488	0.2080	16.1463
	پالایش شده Refined	0.0257	0.0600	0.0443	0.0066	0.0447	-0.2453	-0.4246	14.8070
K _{ShSm}	خام Raw	0.02311	0.14791	0.0926	0.0222	0.094102	-0.3073	-0.3555	23.9937
	پالایش شده Refined	0.0394	0.1412	0.0934	0.0209	0.0945	-0.1978	-0.6463	22.3617
EF	خام Raw	14.0346	42.3999	27.3218	4.8654	26.72871	0.4434	-0.0759	17.8076
	پالایش شده Refined	14.0346	40.5008	27.0895	4.6155	26.6525	0.3082	-0.3272	17.0378

* واحد K_{USLE}، K_{EPIC} و K_{ShSm} (t ha h ha⁻¹ MJ⁻¹ mm⁻¹) و EF_percent (%) است.* The units are K_{USLE}، K_{EPIC} and K_{ShSm} (t ha h ha⁻¹ MJ⁻¹ mm⁻¹) and EF_percent (%).

همبستگی ضرایب فرسایش پذیری و متغیرهای محیطی

در جدول (۴) و شکل (۳ و ۴)، همبستگی سه خصوصیت محیطی داده‌های ژئومورفومتریک، داده‌های خاک و داده‌های سنجش از دور با شاخص‌های K و EF نشان داده شده است. همان‌طور که در (جدول ۳) مشاهده می‌شود، یک همبستگی منفی و معنی‌دار (در سطح ۱ درصد) بین ضرایب فرسایش‌پذیری K و شاخص EF وجود دارد. بررسی ضرایب همبستگی متغیرهای مورد ارزیابی با خصوصیات ژئومورفومتریک در (جدول ۴) نشان می‌دهد که شاخص EF با ویژگی‌های Elv، FD، CNBL، MRRTF و CTA، Stp، MRVBF، VD و CD رابطه منفی دارد. در مقابل، شاخص‌های فرسایش‌پذیری آبی رفتار متفاوتی نشان دادند، به طوری که K_{USLE} تنها با جهت شیب (ASP) رابطه‌ای مستقیم داشته و با ویژگی‌های CNBL، CNL، CD، MRRTF، TanC و RSP رابطه‌ای منفی نشان داده است.


جدول ۴- ضریب همبستگی پیرسون بین شاخص‌های K و EF خاک و متغیرهای محیطی خصوصیات ژئومورفومتريک در منطقه مورد مطالعه.

Table 4. Pearson correlation coefficient between soil K and EF indices and environmental variables of geomorphometric characteristics in the study area.

ضریب فرسایش پذیری متغیر ژئومورفومتريک	K _{USLE}	K _{EPIC}	K _{ShSm}	EF
ASP	0.07*	0.06*	0.06*	-0.02
CTS	-0.00	0.06*	0.06*	-0.06*
CNBL	-0.06*	-0.20***	-0.22***	0.27***
CD	-0.13***	-0.01	0.01	-0.07*
Elv	-0.05	-0.22***	-0.24***	0.28***
FD	-0.03	-0.07**	-0.08**	0.07*
MRRTF	-0.10***	-0.23***	-0.24***	0.23***
MRVBF	-0.01	0.06*	0.07**	-0.12***
RSP	-0.12***	-0.09**	-0.08**	0.01
Slp	0.01	0.07*	0.07*	-0.07*
TanC	-0.05*	-0.05	-0.04	0.03
TRI	0.02	0.06*	0.06*	-0.05
VD	0.03	0.16***	0.18***	-0.20***
CTA	0.05	0.08**	0.08**	-0.06*


*, **, و *** به ترتیب نشان‌دهنده معنادار بودن همبستگی در سطوح احتمال ۰.۰۵، ۰.۰۱ و ۰.۰۰۱ است

*, **, and *** indicate statistically significant correlations at the 0.05, 0.01, and 0.001 probability levels, respectively.



شکل ۳- ضریب همبستگی پیرسون بین شاخص‌های K و EF خاک و متغیرهای محیطی خصوصیات خاک و داده‌های سنجش از دوری لندست ۸ در منطقه مورد مطالعه.

Figure 4. Pearson correlation coefficient between soil K and EF indices and environmental variables of soil properties and remote sensing of Landsat 8 data in the study area.



شکل ۴- ضریب همبستگی پیرسون بین شاخص‌های K و EF خاک و متغیرهای محیطی خصوصیات خاک و داده‌های سنجش از دوری سنتینل ۲ در منطقه مورد مطالعه.

Figure 4. Pearson correlation coefficient between soil K and EF indices and environmental variables of soil properties and remote sensing of Sentinel 2 data in the study area.

در خصوص دو شاخص فرسایش‌پذیری مدل‌های K_{EPIC} و K_{ShSm} ، اگرچه در مورد خصوصیات خاک مورد استفاده در مدل‌سازی (EC)، pH و CCE)، دارای رفتار مشابه با K_{USLE} بودند، اما در ارتباط با سایر متغیرهای مؤثر در فرسایش، همبستگی متفاوتی با شاخص K_{USLE} از خود بروز دادند. به طوری که مشاهده شد این دو شاخص برخلاف انتظار نظری حاصل از روابط تک متغیره، با درصد کربن آلی و رس رابطه مستقیم و با درصد شن خیلی ریز رابطه منفی برقرار

شاخص‌های K_{EPIC} و K_{ShSm} دارای رفتار مشابه یکدیگر اما با کمی تفاوت با K_{USLE} بودند. این دو شاخص علاوه بر شاخص جهت شیب (ASP)، با شاخص‌های CTS، MRVBF، SIp، TRI، CTA و VD رابطه‌ای مستقیم و معنادار نشان دادند و همچنین رابطه‌ای منفی و معنی‌دار با شاخص‌های CND، Elv، FD، MRRTF و RSP نشان دادند که کمی متفاوت از شاخص K_{USLE} بود.

شن رابطه‌ای مثبت و معنی‌دار برقرار کردند. این الگو با شرایط منطقه سازگار است، زیرا خاک‌های شنی معمولاً دارای پوشش گیاهی بهتر و بازتاب طیفی بالاتر هستند، در حالی که خاک‌های رسی، سیلتی و شور دارای پوشش گیاهی ضعیف‌تر و بازتاب کمتری دارند.

برآورد ضرایب فرسایش‌پذیری آبی و بادی با الگوریتم‌های یادگیری ماشین

ارزیابی کارایی مدل‌های یادگیری ماشین در مرحله آزمون برای پیش‌بینی شاخص‌های فرسایش‌پذیری در (جدول ۵) ارائه شده است.

کردند. این تغییر جهت در همبستگی، نه به دلیل تفاوت ماهیتی در ساختار مدل‌ها، بلکه ناشی از تفاوت در رفتار آماری این شاخص‌ها در مواجهه با خاک‌های ناهمگن است؛ به‌گونه‌ای که اثر هم‌زمان و غالب ویژگی‌هایی نظیر سیلت بالا و ساختار ضعیف، باعث خنثی شدن یا معکوس شدن اثر منفی نظری کربن آلی و رس در تحلیل کلان داده‌ها شده است. تحلیل همبستگی متغیرهای ارزیابی‌شده با شاخص‌های سنجش از دور نشان داد که رفتار و الگوی همبستگی شاخص‌های حاصل از دو ماهواره لندست ۸ و سنتینل ۲ با یکدیگر نزدیک و مشابه است. همچنین مشاهده شد که شاخص‌های پوشش گیاهی (EVI, NDVI, RVI, PVI و SAVI) با درصد رس، درصد سیلت و شوری خاک رابطه‌ای منفی و معنی‌دار و در مقابل با درصد

جدول ۵- دقت پیش‌بینی مدل‌های یادگیری ماشین در تخمین ۴ ضریب فرسایش‌پذیری خاک در مرحله آزمون.

Table 5. Prediction accuracy of machine wind models in estimating 4 soil erodibility coefficients in the test phase.

متغیر Variable	مدل Model	میانگین خطا ME	RMSE	RPD	همبستگی پیرسون r	ضریب تبیین	تطابق لین CCC	NRMSE
EF	rpart	-0.4407	3.6981	1.4738	0.7381	0.5448	0.6961	0.6785
	SVM	-0.0148	3.3979	1.6041	0.7927	0.6283	0.7905	0.6234
	Cubist	-0.1634	2.9901	1.8228	0.8362	0.6993	0.8264	0.5486
	RF	-0.5239	3.1978	1.7044	0.8269	0.6837	0.7663	0.5867
K _{USLE}	rpart	0.0016	0.0112	1.4365	0.7239	0.5241	0.6926	0.6961
	SVM	-0.0004	0.0111	1.4470	0.7229	0.5225	0.6742	0.6911
	Cubist	-0.0001	0.0101	1.6039	0.7871	0.6195	0.7351	0.6235
	RF	0.0009	0.0098	1.6486	0.7996	0.6394	0.7580	0.6066
K _{EPIC}	rpart	0.0002	0.0059	1.2388	0.6172	0.3809	0.6025	0.8072
	SVM	0.0001	0.0050	1.4709	0.7333	0.5377	0.7088	0.6798
	Cubist	0.0003	0.0046	1.5802	0.7763	0.6026	0.7369	0.6328
	RF	0.0002	0.0048	1.5191	0.7536	0.5678	0.7104	0.6583
K _{ShSm}	rpart	0.0004	0.0177	1.3057	0.6476	0.4194	0.6185	0.7659
	SVM	0.0010	0.0156	1.4794	0.7406	0.5484	0.6831	0.6759
	Cubist	0.0010	0.0143	1.6088	0.7840	0.6146	0.7545	0.6216
	RF	0.0010	0.0151	1.5317	0.7605	0.5784	0.7115	0.6529

خود نشان داد و در طبقه ضعیف قرار گرفت. برای شاخص K_{USLE}، مدل جنگل تصادفی با کسب بالاترین مقادیر RPD (۱/۶۵)، R² (۰/۶۴) و CCC (۰/۷۶) و پایین‌ترین NRMSE (۰/۶۱)، توانست بر سایر مدل‌ها برتری یابد و به عنوان بهترین برآوردگر برای این شاخص معرفی شود. در مقابل، در سایر متغیرها، مدل Cubist عملکرد برتری را از خود نشان داد. برای شاخص EF Index، مدل Cubist با RPD برابر ۱/۸۲ و NRMSE پایین (۰/۵۵)، عملکردی نزدیک به سطح عالی داشت. همین روند برای دو شاخص دیگر


نتایج نشان می‌دهند که با توجه به پیچیدگی فرآیندهای فرسایش، هیچ‌یک از مدل‌ها به طبقه‌بندی عالی ($RPD > 2$) دست نیافتند، اما عملکرد آن‌ها در دامنه‌های معقول و ضعیف متغیر بود. در این میان، مدل رگرسیون درختی (rpart) رفتاری متفاوتی از خود نشان داد؛ به طوری که برای شاخص EF با RPD برابر ۱/۴۷ و شاخص K_{USLE} با RPD برابر ۱/۴۴، عملکردی در سطح معقول ارائه کرد. با این حال، این مدل در برآورد شاخص‌های پیچیده‌تر یعنی K_{EPIC} ($RPD=1.24$) و K_{ShSm} ($RPD=1.31$) کارایی کمتری از

شناسایی شد. در خصوص ویژگی‌های ژئومورفومتریک، نتایج اهمیت متغیرها نشان داد که چندین متغیر به طور پیوسته اهمیت بالایی را در هر دو مدل فرسایش‌پذیری آبی و بادی نشان می‌دهند. این متغیرها شامل عمق دره، سطح پایه شبکه کانال‌ها، موقعیت شیب نسبی، فاصله شبکه کانال‌ها، ارتفاع و شاخص‌های MRRTF و MRVBF است. همچنین، بررسی اولویت‌بندی متغیرهای ورودی نشان می‌دهد که سلسله‌مراتب اهمیت عوامل محیطی برای متغیرهای EF و K_{ShSm} به ترتیب شامل داده‌های سنجش از دور، ویژگی‌های خاک و متغیرهای ژئومورفومتریک است. در مقابل، برای دو شاخص K_{USLE} و K_{EPIC} ، ویژگی‌های خاک بالاترین وزن را در مدل داشتند و به ترتیب بعد از آن، عوامل ژئومورفومتریک و داده‌های سنجش از دور قرار گرفتند. علاوه بر این، ارزیابی نقش منبع داده‌های ماهواره‌ای حاکی از آن است که شاخص‌های طیفی استخراج شده از سنجنده Sentinel-2 در مقایسه با Landsat-8، تأثیر چشمگیری بر ارتقای عملکرد مدل داشته‌اند.

فرسایش آبی تکرار شد، به طوری که در K_{EPIC} ، Cubist با $RPD=1.58$ و در K_{ShSm} با $RPD=1.61$ ، مقام اول را کسب کرد. مدل RF در این دو شاخص، با وجود اینکه در رده دوم قرار گرفت (مانند K_{EPIC} با $RPD=1.52$)، اما عملکردی پایدارتر نسبت به SVM نشان داد. مدل SVM نیز با وجود عملکرد معقول در تمام متغیرها، هرگز به عنوان مدل برتر ظاهر نشد.

اهمیت متغیرها در برترین الگوریتم پیش‌بینی

مقادیر اهمیت متغیرهای دخیل در تخمین ضرایب سه‌گانه فرسایش‌پذیری آبی (K) و فرسایش‌پذیری بادی (EF) به تفکیک در (شکل ۵) نشان داده شده است. بررسی نتایج مدل‌سازی ضرایب فرسایش‌پذیری آبی نشان می‌دهد که درصد آهک (CCE) بالاترین وزن نسبی را در میان متغیرهای ورودی به خود اختصاص داده است. در مقابل، در شاخص فرسایش‌پذیری بادی (EF)، متغیر تراز پایه شبکه آبراهه (CNBL) به عنوان مهم‌ترین پیش‌بینی‌کننده




شکل ۵- اهمیت متغیرهای الگوریتم‌های یادگیری ماشین (الف) شاخص EF (ب) KUSLE (ج) KEPIC (د) KShSm.
Figure 5. Importance of variables in machine learning algorithms. a) EF index b) KUSLE c) KEPIC d) KShSm.

ساختار بهینه برای هر متغیر در محیط نرم‌افزاری R تولید گردید (شکل ۶). برای تهیه نقشه رستری سه شاخص EF، KEPIC و KShSm از الگوریتم Cubist و برای شاخص KUSLE از مدل جنگل تصادفی استفاده شد.

نقشه‌های رقومی فرسایش پذیری خاک:

پس از انجام مدل‌سازی، نقشه‌های رقومی سه ضریب فرسایش‌پذیری آبی (K) و فرسایش‌پذیری بادی (EF) با استفاده از



شکل ۶- نقشه رقومی فرسایش‌پذیری در منطقه مورد مطالعه.

Figure 6- Digital map of erodibility in the study area.

همان‌گونه که در نقشه‌های تولیدی مشهود است، این دو شاخص فرسایش‌پذیری آبی و بادی الگوهای توزیع مکانی متفاوتی در منطقه مطالعه نشان می‌دهند. بررسی پراکنش مکانی شاخص‌ها نشان می‌دهد که به‌طور خاص، در نواحی جنوبی منطقه مورد مطالعه، مقادیر شاخص K حداقل و مقادیر شاخص EF حداکثر است. با این حال، در سایر بخش‌های منطقه، الگوهای فرسایش‌پذیری متفاوتی مشاهده می‌شود؛ برای شاخص EF، یک گرادیان کاهشی نرم و پیوسته به سمت نواحی شمالی مشاهده می‌شود و مقادیر حداقل عمدتاً در حاشیه‌های شمالی قرار دارند. در مقابل، افزایش مقادیر K به طرف شمال منطقه مورد مطالعه به صورت پراکنده و فاقد روند خاصی است و بیشینه‌های K در حاشیه‌های شرقی و سپس غربی متمرکز شده‌اند. مقایسه نقشه‌های توزیع مکانی سه شاخص فرسایش‌پذیری آبی نشان می‌دهد که الگوی کلی حاصل از این سه معادله تا حد زیادی مشابه یکدیگر هستند. با این وجود، واکاوی جزئیات بیانگر آن است که الگوی پراکنش K_{ShSm} و K_{EPIC} هم‌پوشانی مکانی بالایی با یکدیگر دارند، در حالی که توزیع مکانی K_{USLE} تفاوت‌های قابل‌توجهی با این دو مدل از خود نشان می‌دهد. از سوی دیگر، اگرچه K_{ShSm} و K_{EPIC} از نظر الگوی مکانی مشابه‌اند، اما از نظر کمی، مدل K_{ShSm} مقادیر فرسایش‌پذیری بالاتری را در نقاط هم‌موقعیت (متناظر) نسبت به K_{EPIC} برآورد می‌کند.

بحث

تحلیل توزیع آماری و تغییرپذیری داده‌ها

مقادیر چولگی که به خوبی در آستانه $1 \pm$ قرار می‌گیرند، معمولاً به عنوان نشانه‌ای از توزیع تقریباً نرمال تفسیر می‌شوند (Bameri et al., 2015; Bulmer, 1979). این رفتار تقریباً نرمال مشاهده شده در شاخص‌های این مطالعه، هم برای استنتاج آماری و هم برای مدل‌سازی فرسایش خاک مبتنی بر یادگیری ماشین می‌تواند بسیار مفید و حیاتی باشد، زیرا احتمال سوگیری ناشی از بی‌نظمی‌های توزیع را به شدت کاهش می‌دهد. در خصوص شاخص‌های پراکندگی، باید توجه داشت که به جز ضریب تغییرات، سایر معیارها به مقیاس اندازه‌گیری داده‌ها وابسته‌اند و در نتیجه برای مقایسه معیار پراکندگی بین دو یا چند جامعه مناسب نیستند. این ضریب، بیش‌تر در مورد تغییرپذیری نسبی متغیرها ارائه می‌دهد. طبق طبقه‌بندی Wilding و همکاران (۱۹۸۳)، اگر ضریب تغییرات کمتر از ۱۵ درصد باشد، داده‌ها دارای تغییرپذیری کم هستند؛ اگر مقدار این ویژگی بین ۱۵ تا ۳۵ درصد باشد، کلاس تغییرپذیری متوسط و در صورتی که بیشتر از ۳۵ درصد باشد، حاکی

از تغییرپذیری زیاد است. بر مبنای این چارچوب نظری، نتایج حاصل از این پژوهش نشان‌دهنده تغییرپذیری متوسط برای اکثر شاخص‌ها است. این یافته‌ها با مطالعه Mallick و همکاران (۲۰۱۵) در زمینه نقشه‌برداری رقومی شاخص فرسایش‌پذیری خاک در عربستان سعودی هم‌راستا است. آن‌ها مقدار CV داده‌های KUSLE را ۱۵٪ گزارش کرده‌اند که در طبقه‌بندی تغییرپذیری متوسط قرار می‌گیرد. همچنین، مقادیر چولگی (۰/۷۶) و کشیدگی (۱/۲۵) گزارش شده در آن پژوهش نیز نشان‌دهنده توزیع نسبتاً نرمال داده‌هاست که تأییدکننده نتایج به دست آمده در منطقه مطالعه حاضر است نکته مهم در تفسیر نتایج حاضر آن است که مقادیر فرسایش‌پذیری برآوردشده توسط روابط تجربی (مانند موارد ارائه‌شده در این مطالعه)، ذاتاً حاوی نوعی بیش‌برآوردی در مقایسه با هدر رفت واقعی اندازه‌گیری‌شده در کرت‌های میدانی هستند. همان‌طور که پژوهش‌های اخیر در شرایط اقلیمی مشابه گزارش کرده‌اند (Avizhgan et al., 2025)، این بیش‌برآوردی گاهی بسیار چشمگیر است. دلیل این امر آن است که این فرمول‌ها فرسایش‌پذیری اسمی خاک را در شرایط استاندارد یک کرت لخت محاسبه می‌کنند و از سوی دیگر، پدیده‌های مهارکننده موضعی نظیر اثر سنگریزه‌ها، زبری سطح و مهم‌تر از همه کمبود فراوانی رخدادهای بارشی بسیار شدید در مناطق خشک را نادیده می‌گیرند.

تحلیل روابط همبستگی و تفسیر فیزیکوشیمیایی

مشاهده همبستگی منفی بین ضرایب K و EF با یافته‌های Han و همکاران (۲۰۲۳) که در بررسی رسوبات لسی چین رابطه‌ای منفی و معنی‌دار ($r = -0.57^{**}$) را بین این دو شاخص گزارش کردند، هم‌راستا است. این پدیده را می‌توان ناشی از تفاوت در ساختار فرمولی این دو شاخص دانست؛ زیرا در شاخص EF، درصد شن نقش تعیین‌کننده‌ای دارد و با آن رابطه‌ای مستقیم برقرار می‌کند، در حالی که این متغیر با ضریب K رابطه معکوس دارد (Abiye & Dengiz., 2025). این تفاوت در وزن‌دهی به اجزای بافت خاک و شرایط خاص خاک‌شناسی منطقه، منجر به رفتار معکوس این دو شاخص در منطقه مورد مطالعه شده است.

روابط متفاوت مشاهده شده بین شاخص‌های فرسایش و عوامل توپوگرافی بیانگر تأثیر شکل زمین بر پتانسیل فرسایش در منطقه است (Santos et al., 2025). با توجه به شرایط منطقه و مطالعات مشابه در زمینه نقشه‌برداری رقومی اراضی سیلابی و مناطق با پستی‌بلندی کم، شاخص‌هایی مانند MRVBF، MRRTF، VD، CNBL، Elv و RSP در نشان دادن فرآیند انتقال رسوب

شن مشاهده شد. این الگو ریشه در ویژگی‌های اقلیمی و ژئومورفولوژیکی منطقه مورد مطالعه دارد که به عنوان یک دشت سیلابی، پذیرنده رسوبات ریزدانه و املاح محلول از رودخانه هیرمند است. ذرات رس و سیلت (که می‌توانند به دلیل پوشش سطحی با رس‌های کلوییدی دارای بار منفی جزئی باشند) به واسطه سطح ویژه بالا و بارهای الکتریکی، قابلیت جذب و نگهداری کاتیون‌ها و املاح را دارند. تبخیر بالا در این منطقه موجب صعود و تجمع نمک‌ها در سطح خاک شده که در نهایت منجر به کاهش توان رویشی و تضعیف شاخص‌های پوشش گیاهی در خاک‌های شور و ریزدانه می‌گردد (Allbed & Kumar, 2013). این وضعیت موجب می‌شود شاخص‌های سنجش از دور یادشده، مقادیر پایین‌تری را در این مناطق ثبت کنند. در مقابل، در خاک‌های با بافت درشت‌تر (درصد شن بالا)، به دلیل آبشویی بهتر و ظرفیت تبادل کاتیونی پایین‌تر، شوری کمتری تجمع یافته و شرایط برای استقرار پوشش گیاهی متراکم‌تر مساعدتر است.

تحلیل عملکرد الگوریتم‌ها و دلایل برتری مدل

عملکرد دوگانه مدل rpart نشان می‌دهد که این مدل برای روابط نسبتاً ساده‌تر می‌تواند کارآمد باشد، اما کاهش کارایی شدید آن در تخمین K_{ShSm} و K_{EPIC} ناشی از محدودیت‌های ساختاری تک‌درختی در مدل‌سازی ناهمگونی‌های پیچیده خاک است. برتری مدل جنگل تصادفی در پیش‌بینی K_{USLE} حاکی از آن است که ساختار گروهی درخت و تصادفی‌سازی در مدل RF، تطابق بسیار خوبی با ماهیت متغیرهای ورودی مدل در برآورد این شاخص داشته است (Tian et al., 2022). با این حال، نتایج این مطالعه در خصوص RF نکات قابل تأملی دارد. اگرچه RF به عنوان یکی از اثبات‌شده‌ترین الگوریتم‌ها در نقشه‌برداری رقومی خاک شناخته می‌شود و عملکرد برتر آن در پیش‌بینی K_{USLE} پتانسیل بالای آن را در استخراج روابط فیزیکی پنهان تأیید می‌کند (Ma et al., 2022)، اما عملکرد پایین‌تر آن نسبت به Cubist در سه شاخص دیگر (EF ، K_{ShSm} و K_{EPIC}) نشان‌دهنده یک نکته مهم است، این امر بیانگر آن است که حتی الگوریتم‌های قدرتمند نظیر RF نیز ممکن است در برابر مدل‌های مبتنی بر قانون^۲ مانند Cubist که انعطاف‌پذیری بیشتری در تنظیم روابط غیرخطی محلی دارند، در برخی چشم‌اندازها عقب بمانند. با این وجود، ثبات و پایداری RF در تمامی متغیرها (همیشه در رده اول یا دوم) و نداشتن عملکرد ضعیف، آن را همچنان

به ویژه جریان رسوبات و مواد در حال حرکت مؤثر گزارش شده‌اند (Mosleh et al., 2016; Pahlavan rad & Akbarimoghaddam, 2018). این مطالعات همچنین بر نقش عوامل توپوگرافی و ناهم‌واری‌های سطح زمین در فرسایش‌پذیری بادی تأکید دارند (Rezaei et al., 2023; Kulmatiski et al., 2025).

تفاوت در الگوی همبستگی آماری K_{ShSm} و K_{EPIC} با سایر شاخص‌ها، از نظر فضایی بازتاب‌دهنده تفاوت در حساسیت این مدل‌ها به ویژگی‌های خاک است. از آنجا که واحدهای ژئومورفیک عامل اصلی کنترل توزیع فضایی این ویژگی‌ها (مانند ساختار و بافت) هستند، خروجی مدل‌های K_{ShSm} و K_{EPIC} به شدت تحت تأثیر الگوهای ژئومورفیک قرار می‌گیرد، موضوعی که در همبستگی متفاوت این شاخص‌ها با سایر متغیرها مشهود است. یافته‌های این پژوهش نشان داد که برخلاف مبانی نظری تک‌متغیره شاخص K_{USLE} (که همیشه رابطه معکوس بین کربن آلی و فرسایش‌پذیری را متصور می‌شود)، شاخص‌های K_{ShSm} و K_{EPIC} در مقیاس کلان منطقه، رابطه مستقیمی با کربن آلی و رس نشان دادند. این تغییر جهت در همبستگی، نه به دلیل خطای محاسباتی، بلکه تابع پیچیدگی‌های آماری در خاک‌های ناهمگن است. به گونه‌ای که در مناطقی با سیلت بالا، ساختار ضعیف و شرایط خاص مدیریتی (نظیر تأثیرات شوری ثانویه)، اثر غالب این متغیرهای حساس بر اثر منفی کربن آلی در فرمول برتری می‌یابد (Bonilla and Johnson, 2012). در واقع، در چنین محیط‌های پیچیده، شاخص‌های سنتی که بر پایه روابط ساده و ایزوله ساخته شده‌اند، نمی‌توانند دینامیک واقعی خاک (مانند اثرات متقابل بافت، شوری و پوشش) را به درستی بازتاب دهند و دچار سوگیری^۱ می‌شوند (Salcedo et al., 2021)؛ بنابراین، حساسیت بالای K_{ShSm} و K_{EPIC} به تغییرات بافتی و مواد آلی در شرایط ناهمگن این منطقه نشان می‌دهد که استفاده از این شاخص‌ها در مدل‌سازی‌های مکانی، نیازمند واسنجی مجدد یا بازنگری در انتخاب شاخص‌های فرسایش‌پذیری متناسب با شرایط اقلیمی و ژئومورفیک منطقه است.

در تفسیر همبستگی‌های آماری میان شاخص‌های پوشش گیاهی ($SAVI$ ، PVI ، RVI ، $NDVI$ ، EVI) با ویژگی‌های فیزیکوشیمیایی خاک، الگوی مشاهده شده حاکی از وجود رابطه‌ای منفی و معنی‌دار میان این شاخص‌ها با درصد رس، درصد سیلت و شوری خاک است، در حالی که رابطه مثبت و معنی‌داری با درصد

² Rule-based

¹ Bias

شاخص‌های طیفی استخراج شده از سنجنده Sentinel-2 نسبت به Landsat-8، ناشی از قدرت تفکیک مکانی و طیفی بالاتر این سنجنده است که امکان تشخیص دقیق‌تر تغییرات پوشش سطحی و بافت خاک را فراهم کرده و در نهایت منجر به بهبود عملکرد مدل‌ها شده است.

تحلیل الگوهای مکانی و نقشه رقومی فرسایش‌پذیری خاک

الگوی مشاهده شده در جنوب منطقه که در آن شاخص K کمینه و شاخص EF بیشینه است، نشان‌دهنده تأثیر مستقیم درصد شن بر کاهش فرسایش‌پذیری آبی و افزایش فرسایش‌پذیری بادی است. همچنین، تمرکز مقادیر بالای K در حاشیه‌های شرقی و غربی و الگوی پراکنده آن در شمال، منطبق بر مناطقی است که دارای بیشترین درصد سیلت در منطقه مطالعه می‌باشند. این تأیید می‌کند که نقشه‌های تولید شده قادرند پیچیدگی‌های بافتی خاک را به خوبی بازتاب دهند. در نهایت، نتایج حاصل از این نقشه‌ها نشان می‌دهد که الگوریتم‌های یادگیری گروهی مبتنی بر درخت (Cubist و RF)، با انتخاب بهینه متغیرهای محیطی پیش‌بینی‌کننده، از ظرفیت بالایی برای تهیه نقشه‌های پراکنش مکانی فرسایش‌پذیری در تفکیک مکانی ۳۰ متری برخوردارند. نکته‌ی حائز اهمیت آن است که این مدل‌ها، علی‌رغم عدم ورود مستقیم متغیرهای بافت خاک به عنوان ورودی، موفق شدند با استخراج روابط نهفته در داده‌های کمکی (مانند توپوگرافی و شاخص‌های طیفی)، تأثیر بنیادین بافت بر فرسایش‌پذیری آبی و بادی را به خوبی شبیه‌سازی و در ساختار مکانی خاک بازتاب دهند. این مسئله نشان‌دهنده پتانسیل بالای روش‌های یادگیری ماشین در استخراج متغیرهای پنهان خاک از طریق داده‌های کمکی است.

نتیجه‌گیری

فرسایش‌پذیری خاک در دشت سیستان تحت تأثیر ترکیب پیچیده‌ای از ویژگی‌های خاک، شرایط سطحی و عوامل محیطی قرار دارد و مدل‌سازی مکانی آن نیازمند رویکردهای پیشرفته نقشه‌برداری رقومی خاک (DSM) است. نتایج این پژوهش نشان داد که تلفیق داده‌های خاک، شاخص‌های ژئومورفومتریک و اطلاعات سنجش‌ازدور، همراه با الگوریتم‌های یادگیری ماشین، می‌تواند برآوردهای قابل‌اعتماد و مکانی از شاخص‌های فرسایش‌پذیری آبی (K) و بادی (EF) ارائه دهد. رفتار متفاوت شاخص‌های گیاهی در خاک‌های شور و ریزبافت که به ایجاد همبستگی منفی میان

به گزینه‌ای ایمن و قدرتمند برای مطالعات پیش‌بینی خصوصیات خاک و فرسایش خاک تبدیل کرده است.

در نهایت، می‌توان جمع‌بندی کرد که اگرچه مدل Cubist به دلیل عملکرد برتر در برآورد هر سه شاخص فرسایش‌پذیری، به عنوان کلی‌ترین انتخاب برای این مطالعه پیشنهاد می‌شود، اما انتخاب نهایی مدل باید وابسته به هدف خاص مطالعه باشد. به طوری که برای پروژه‌های مبتنی بر معادله USLE، استفاده از RF و برای سایر موارد استفاده از Cubist اولویت دارد. مدل rpart نیز تنها در صورت محدودیت منابع محاسباتی و برای برآوردهای اولیه EF و KUSLE قابل توصیه است.

تفسیر اهمیت متغیرها و نقش عوامل محیطی

تفاوت در الگوی اولویت‌بندی اهمیت متغیرها در مدل‌های یادگیری ماشین (بین CCE برای K و CNBL برای EF) بیانگر آن است که مدل EF در مقایسه با مدل K، حساسیت کمتری به تغییرات ویژگی‌های ذاتی خاک دارد و بیشتر تحت تأثیر عوامل سطحی و مکانی قرار می‌گیرد. لازم به تأکید است که فرسایش‌پذیری بادی یک ویژگی ذاتی خاک است، اما در مدل‌سازی مکانی، الگوی توزیع EF در چشم‌انداز می‌تواند تحت تأثیر متغیرهای توپوگرافی قرار گیرد، زیرا توپوگرافی بر شرایط سطحی مانند رطوبت، تجمع رسوبات، زبری سطح و پوشش گیاهی اثر غیرمستقیم دارد. شاخص CNBL نیز دقیقاً همین اثرات سطحی را بازتاب می‌دهد. این یافته با تحقیقات Usta (۲۰۲۲) هم‌راستا است که بیان می‌کند توپوگرافی گروه مهم‌تری از متغیرها بوده که بر شاخص‌های فرسایش‌پذیری خاک تأثیر می‌گذارند و اهمیت ویژگی توپوگرافی را در پیش‌بینی بیش از ۵۵ درصد گزارش می‌کند. همچنین، Hengl و همکاران (۲۰۱۸) در مطالعات خود تأکید می‌کنند توپوگرافی یکی از مهم‌ترین پیش‌بین‌های مکانی ویژگی‌های خاک است، حتی اگر آن ویژگی ذاتاً تابع خاک باشد.

در تبیین نقش متغیرهای ژئومورفومتریک مشترک، باید توجه داشت که عمق دره یک متغیر ژئومورفومتریک اساسی است که بر غلظت جریان آب و سرعت رواناب تأثیر می‌گذارد (Zheng et al., 2000) و در نتیجه به طور قابل توجهی بر حساسیت فرسایش آبی اثر می‌گذارد. این یافته با تحلیل‌های Morgan (۲۰۰۵) که بر نقش مورفولوژی دره در دینامیک رواناب تأکید دارد، دارای همخوانی کامل است. شناسایی این متغیرها به عنوان پیش‌بینی‌کننده‌های کلیدی در هر دو نوع فرسایش، نشان‌دهنده نقش اساسی توپوگرافی در کنترل فرآیندهای فرسایشی در منطقه است. همچنین، برتری

NDVI/EVI و درصد رس منجر شد، نشان داد که ویژگی‌های اکوسیستم‌های دشتی و شور نقش تعیین‌کننده‌ای در تبیین الگوی مکانی فرسایش‌پذیری دارند. همچنین، ارزیابی سه معادله تجربی K نشان داد که K_{USLE} سازگاری بیشتری با شرایط منطقه دارد، در حالی که K_{EPIC} و K_{ShSm} نیازمند واسنجی مجدد یا بازنگری برای کاربردهای محلی هستند.

در بخش مدل‌سازی، الگوریتم کیوبیست بهترین عملکرد را در پیش‌بینی EF ، K_{EPIC} و K_{ShSm} ارائه داد و جنگل تصادفی دقیق‌ترین مدل برای K_{USLE} بود. تحلیل اهمیت متغیرها نیز نشان داد که درصد آهک (CCE) مهم‌ترین عامل در مدل‌سازی K و شاخص تراز پایه آبراهه (CNBL) مؤثرترین متغیر در مدل EF است، موضوعی که بیانگر نقش غالب شرایط سطحی و توپوگرافی در توزیع مکانی فرسایش‌پذیری بادی است. به‌طور کلی، این پژوهش نشان می‌دهد که استفاده از الگوریتم‌های یادگیری ماشین در چارچوب DSM، رویکردی کارآمد برای مدل‌سازی مکانی فرسایش‌پذیری در مناطق خشک و کم ارتفاع است و می‌تواند مبنایی برای توسعه روش‌های مشابه در مناطق همگن جهان باشد. با این وجود، از محدودیت‌های پژوهش حاضر، عدم اندازه‌گیری نسبت جذب سدیم (SAR) به دلیل وسعت منطقه و تعداد زیاد نمونه‌ها بود، با توجه به تأثیر مهم این شاخص بر پایداری ساختمان خاک و فرسایش‌پذیری، سنجش آن در مطالعات آینده پیشنهاد می‌شود.

تعارض منافع

نویسندگان این مقاله اعلام می‌کنند که هیچ‌گونه تعارض منافی در خصوص انتشار این مقاله وجود ندارد.

References

1. Abiye, W. and Dengiz, O., 2025. Digital mapping of soil erodibility factor in response to land use change using machine learning models. *Environmental Systems Research*, 14(14). <https://doi.org/10.1186/s40068-025-00402-w>
2. Allbed, A. and Kumar, L., 2013. Soil salinity mapping and monitoring in arid and semi-arid regions using remote sensing technology: A review. *Advances in Remote Sensing*, 2(4), pp.373–385. <https://doi.org/10.4236/ars.2013.24040>
3. Asadi, H., Besharati, H. and Gorji, M., 2022. Challenges and limitations of soil and land resources in Iran. *Land Management*, 1 (1), pp. 111-135. <https://doi.org/10.22092/lmj.2022.358760.309> (In Persian)
4. Auerswald, K., Fiener, P., Martin, W. and Elhaus, D., 2014. Use and misuse of the K factor equation in soil erosion modeling. *Catena*, 118, pp.220–225. <https://doi.org/10.1016/j.catena.2014.01.008>
5. Auerswald, K., Fiener, P., Martin, W. and Elhaus, D., 2016. Corrigendum to “Use and misuse of the K factor equation in soil erosion modeling” [CATENA 118 (2014) 220–225]. *Catena*, 139, p.271. <https://doi.org/10.1016/j.catena.2015.05.026>
6. Avizhgan, A., Asadi, H., Arabkhedri, M., Noor, H., Nazari Samani, A. A., 2025. The challenges of measuring and estimating the soil erodibility factor (K) of the (R)USLE model in rangelands of arid regions. *Iranian Journal of Soil and Water Research*, 56(2), pp. 351-371. <https://doi.org/10.22059/ijswr.2024.386195.669845> (In Persian)
7. Barbut, M. and Alexander, S., 2016. Land degradation as a security threat amplifier: The new global frontline. In: Chabay, I., Frick, M. and Helgeson, J., eds. *Land Restoration*. Academic Press, pp.3–12. ISBN 9780128012314.
8. Bameri, A., Khormali, F., Kiani, F. and Dehghani, A.A., 2015. Spatial variability of soil organic carbon in different hillslope positions in Toshan area, Golestan Province, Iran: Geostatistical approaches. *Journal of Mountain Science*, 12(6), pp.1422–1433. <https://doi.org/10.1007/s11629-014-3213-z>
9. Bonilla, C.A. and Johnson, O.I. 2012. Soil erodibility mapping and its correlation with soil properties in Central Chile. *Geoderma*, 189–190, pp. 116–123. <https://doi.org/10.1016/j.geoderma.2012.05.005>
10. Borrelli, P., Robinson, D., Fleischer, L.R., Lugato, E., Ballabio, C., Alewell, C., Meusburger, K., Modugno, S., Schütt, B., Ferro, V., Bagarello, V., Van Oost, K., Montanarella, L. and Panagos, P. 2017. An assessment of the global impact of 21st century land use change on soil erosion. *Nature Communications*, 8, pp. 2013. <https://doi.org/10.1038/s41467-017-02142-7>
11. Bulmer, M.G., 1979. *Principles of Statistics*. Dover Publications, Mineola, NY.
12. Fenta, A.A., Tsunekawa, A., Haregeweyn, N., Poesen, J., Tsubo, M., Borrelli, P., Panagos, P., Vanmaercke, M., Broeckx, J., Yasuda, H., Kawai, T. and Kurosaki, Y., 2019. Land susceptibility to water and wind erosion risks in the East Africa region. *The Science of the Total Environment*, 703, 135016. <https://doi.org/10.1016/j.scitotenv.2019.135016>
13. Fryrear, D.W., Saleh, A., Bilbro, J.D., Schomberg, H.M., Stout, J.E. and Zobeck, T.M., 1998. Revised Wind Erosion Equation (RWEQ). USDA-ARS Wind Erosion and Water Conservation Research Unit, Technical Bulletin No.1.
14. Ghosh, A. and Maiti, R., 2021. Soil erosion susceptibility assessment using logistic regression, decision tree and random forest: Study on the Mayurakshi river basin of Eastern India. *Environmental Earth Sciences*, 80, 328. <https://doi.org/10.1007/s12665-021-09631-5>
15. Gholami, H., Mohammadifar, A., Golzari, S., Kaskaoutis, D.G. and Collins, A.L., 2021. Using the Boruta algorithm and deep learning models for mapping land susceptibility to atmospheric dust emissions in Iran. *Aeolian Research*, 50, 100682. <https://doi.org/10.1016/j.aeolia.2021.100682>
16. Guerra, C.A., Rosa, E., Valentini, F., Wolf, F., Filipponi, F., Karger, D.N., Xuan, A.N., Mathieu, J., Lavelle, P. and Eisenhauer, N., 2020. Global vulnerability of soil ecosystems to erosion. *Landscape Ecology*, 35(6),

- pp.823–842. <https://doi.org/10.1007/s10980-020-00984-z>
17. Han, Y., Zhao, W., Ding, J. and Ferreira, C.S.S., 2023. Soil erodibility for water and wind erosion and its relationship to vegetation and soil properties in China's drylands. *Science of the Total Environment*, 903, 166639. <https://doi.org/10.1016/j.scitotenv.2023.166639>
18. Huete, A.R., Liu, H.Q., Batchily, K. and Van Leeuwen, W., 1997. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote Sensing of Environment*, 59, pp.440–451. [https://doi.org/10.1016/S0034-4257\(96\)00112-5](https://doi.org/10.1016/S0034-4257(96)00112-5)
19. Husson, O., Bruneta, A., Babrec, D., Charpentier, H., Durande, M. and Sarthou, J.P., 2018. Conservation agriculture systems alter the electrical characteristics (Eh, pH and EC) of four soil types in France. *Soil & Tillage Research*, 176, pp.57–68. <https://doi.org/10.1016/j.still.2017.11.005>
20. Jafari, M., Tahmoures, M., Ehteram, M., Ghorbani, M. and Panahi, F., 2022. Soil erosion: Factors, processes and effects. In: *Soil Erosion Control in Drylands*. Springer, Cham. https://doi.org/10.1007/978-3-031-04859-3_1
21. Kanianska, R., Kizeková, M., Jančová, L., Cunderlík, J. and Dugátová, Z., 2024. Effect of soil erosion on soil and plant properties with a consequence on related ecosystem services. *Sustainability*, 16(16), 7037. <https://doi.org/10.3390/su16167037>
22. Kjelland, M.E., Woodley, C.M., Swannack, T.M. and Smith, D.L., 2015. A review of the potential effects of suspended sediment on fishes: Potential dredging-related physiological, behavioral, and transgenerational implications. *Environmental Systems and Decisions*, 35, pp.334–350.
23. Khosravi, K., Rezaie, F., Cooper, J.R., Kalantari, Z., Abolfathi, S. and Hatamiafkouei, J., 2023. Soil water erosion susceptibility assessment using deep learning algorithms. *Journal of Hydrology*, 618, 129229. <https://doi.org/10.1016/j.jhydrol.2023.129229>
24. Kulmatiski, A., Ozturk, M., Bladen, K.K., Brahney, J. and Duniway, M.C., 2025. Season, wind speed, and seasonal rain are major drivers of a regional aeolian sediment transport model. *PLoS One*, 20(9), e0333166. <https://doi.org/10.1371/journal.pone.0333166>
25. Kursa, M.B. and Rudnicki, W.R., 2010. Feature selection with the Boruta package. *Journal of Statistical Software*, 36(11), pp.1–13.
26. Lucieer, A., Malenovsky, Z., Veness, T. and Wallace, L., 2014. HyperUAS imaging spectroscopy from a multirotor unmanned aircraft system. *Journal of Field Robotics*, 31(4), pp.571–590.
27. Ma, R., Zhu, X., Tian, Z., Qu, L., He, Y. and Liang, Y., 2022. Spatial distribution and scale-specific controls of soil water-stable aggregates in southeastern China. *Journal of Cleaner Production*, 369, 133305. <https://doi.org/10.1016/j.jclepro.2022.133305>
28. Mallick, J., Al-Wadi, H., Rahman, A., Ahmed, M. and Khan, R.A., 2015. Spatial variability of soil erodibility and its correlation with soil properties in semi-arid mountainous watershed, Saudi Arabia. *Geocarto International*, 31(6), pp. 661–681. <https://doi.org/10.1080/10106049.2015.1073368>
29. Mazarei, A., Sousa, R., Mendes-Moreira, J., Molchanov, S. and Ferreira, H.M., 2025. Online boxplot derived outlier detection. *International Journal of Data Science and Analytics*, 19, pp.83–97. <https://doi.org/10.1007/s41060-024-00559-0>
30. McBratney, A.B., Mendonça Santos, M.L. and Minasny, B., 2003. On digital soil mapping. *Geoderma*, 117(1–2), pp.3–52. [https://doi.org/10.1016/S0016-7061\(03\)00223-4](https://doi.org/10.1016/S0016-7061(03)00223-4)
31. Mirakzehi, K., Pahlavan-Rad, M.R., Shahriari, A. and Bameri, A., 2018. Digital soil mapping of deltaic soils: A case study from Hirmand (Helmand) river delta. *Geoderma*, 313, pp.233–240. <https://doi.org/10.1016/j.geoderma.2017.10.048>
32. Morgan, R., 2005. *Soil Erosion and Conservation*. 3rd ed. Blackwell Publishing Ltd., Carlton.
33. Mosleh, Z., Salehi, M.H., Jafari, A., Borujeni, I.E. and Mehnatkesh, A., 2016. The effectiveness of digital soil mapping to predict soil properties over low-relief areas. *Environmental Monitoring and Assessment*, 188, pp.1–13.
34. Nourafar, A., Pahlavanrabi, A., Nohtani, M., and Rahdari, V., 2022. Investigation of Wind

- Erosion Threshold in Different Land Cover and the Effect of Soil Properties on It (Case Study: Niatak Region of Sistan). *Jwss*, 26 (1), pp. 41-54.
<https://doi.org/10.47176/jwss.26.1.6212>
35. Olmstead, L.B., Alexander, L.T. and Middleton, H.E., 1930. A pipette method of mechanical analysis of soils based on improved dispersion procedure. *Technical Bulletin*, No.170, USDA, Washington, DC.
 36. Otto, S.A., Kadin, M., Casini, M., Torres, M.A. and Blenckner, T., 2018. A quantitative framework for selecting and validating food web indicators. *Ecological Indicators*, 84, pp.619–631.
<https://doi.org/10.1016/j.ecolind.2017.05.045>
 37. Ouri, A., Golshan, M., Janizadeh, S., Cerdà, A. and Melesse, A.M., 2020. Soil erosion susceptibility mapping in Kozetopraghi catchment, Iran: A mixed approach using rainfall simulator and data mining techniques. *Land*, 9(10), 368.
<https://doi.org/10.3390/land9100368>
 38. Pahlavan-Rad, M.R. and Akbarimoghaddam, A., 2018. Spatial variability of soil texture fractions and pH in a flood plain (case study from eastern Iran). *Catena*, 160, pp.275–281.
<https://doi.org/10.1016/j.catena.2017.10.002>
 39. Parajuli, M., Cristan, R., Daniel, M.J., Rijal, A., Mitchell, D., McDonald, T. and Gallagher, T., 2025. Integrating high-resolution imagery, deep learning, and GIS to estimate soil erosion following timber harvesting. *Remote Sensing Applications: Society and Environment*, 37, 101498.
<https://doi.org/10.1016/j.rsase.2025.101498>
 40. Planchon, O. and Darboux, F., 2001. A fast, simple and versatile algorithm to fill the depressions of digital elevation models. *Catena*, 46, pp.159–176.
 41. Rahmati, O., Ahmadi Dehrshid, F., Soleimanpour, S.M. and Choubin, B., 2025. A review of some studies, methods and estimates of soil erosion and sediment yield in Iran. *Iranian Journal of Water and Soil Research*, 56 (5), pp. 1119-1145.
<https://doi.org/10.22059/ijswr.2025.388015.669866> (In Persian)
 42. Rezaei, M., Mohammadifar, A., Gholami, H., Mina, M., Riksen, M. and Ritsema, C., 2023. Mapping of the wind erodible fraction of soil by bidirectional gated recurrent unit (BiGRU) and bidirectional recurrent neural network (BiRNN) deep learning models. *Catena*, 223, 106953.
<https://doi.org/10.1016/j.catena.2023.106953>
 43. Salcedo, F.P., Cutillas, P.P., Cabañero, J.J.A. and Vivaldi, A.G. 2021. Use of remote sensing to evaluate the effects of environmental factors on soil salinity in a semi-arid area. *The Science of the Total Environment*, 794, 152524.
<https://doi.org/10.1016/j.scitotenv.2021.152524>
 44. Santos, A.d.S., Silva Júnior, J.F.d., Santos, L.d.S., Alencar Sobrinho, R.J., Amorim, E.C., Fernandes, G.S.T., Silva, E.F.d., Silva, T.G.F.d., de Lima, J.L.M.P. and Jardim, A.M.d.R.F., 2025. Identification of priority areas for the control of soil erosion and the influence of terrain factors using RUSLE and GIS in the Caeté River Basin, Brazilian Amazon. *Earth*, 6, 35.
<https://doi.org/10.3390/earth6020035>
 45. Sharpley, A.N. and Smith, S.J., 1990. Phosphorus transport in agricultural runoff: The role of soil erosion. In: *Soil Erosion on Agricultural Land*. John Wiley & Sons Ltd., pp.351–366.
 46. Sparks, D.L., Page, A.L., Helmke, P.A., Loeppert, R.H., Soltanpour, P.N., Tabatabai, M.A., Johnston, C.T. and Sumner, M.E., 1996. *Methods of Soil Analysis: Part 3, Chemical Methods*. Soil Science Society of America and American Society of Agronomy.
<https://doi.org/10.2136/sssabookser5.3>
 47. Sun, L., Liu, F., Zhu, X. and Zhang, G., 2024. High-resolution digital mapping of soil erodibility in China. *Geoderma*, 444, 116853.
<https://doi.org/10.1016/j.geoderma.2024.116853>
 48. Taghizadeh-Mehrjardi, R., Minasny, B., Sarmadian, F. and Malone, B.P., 2014. Digital mapping of soil salinity in Ardakan region, central Iran. *Geoderma*, 213, pp.15–28.
<https://doi.org/10.1016/j.geoderma.2013.07.020>
 49. Tian, Z., Liu, F., Liang, Y. and Zhu, X., 2022. Mapping soil erodibility in Southeast China at 250 m resolution: Using environmental variables and random forest regression with limited samples. *International Soil and Water Conservation Research*, 10(1), pp.62–74.
<https://doi.org/10.1016/j.iswcr.2021.06.005>
 50. Torkamani, F., Piri Sahragard, H., Pahlavan Rad, M.R. and Nohtani, M., 2026. Digital mapping of soil erodibility: A case study of the Ravang watershed, southern Iran.

- Agrosystems, Geosciences & Environment*, 9(1), pp. e70285.
<https://doi.org/10.1002/agg2.70285>
51. Usta, A., 2022. Prediction of soil water contents and erodibility indices based on artificial neural networks: Using topography and remote sensing. *Environmental Monitoring and Assessment*, 194, 794. <https://doi.org/10.1007/s10661-022-10465-2>
52. Wang, J.J., Huang, Y.F. and Long, H.Y., 2016. Water and salt movement in different soil textures under various negative irrigating pressures. *Journal of Integrative Agriculture*, 15(8), pp.1874–1882. [https://doi.org/10.1016/S2095-3119\(15\)61209-6](https://doi.org/10.1016/S2095-3119(15)61209-6)
53. Wilding, L.P., Smeck, N.E. and Hall, G.F., 1983. *Pedogenesis and Soil Taxonomy. I. Concepts and Interactions*. Elsevier, Amsterdam, 303 p.
54. Williams, J.R., Renard, K.G. and Dyke, P.T., 1983. EPIC: A new method for assessing erosion's effect on soil productivity. *Journal of Soil and Water Conservation*, 38(5), pp.381–383.
55. Wischmeier, W.H. and Smith, D.D., 1978. *Predicting Rainfall Erosion Losses: A Guide to Conservation Planning*. USDA, Agriculture Handbook No.537.
56. Zeraatpisheh, M., White, A., Darby, H., Neher, D.A., Faulkner, J., Hancock, L. and Galford, G.L., 2025. Spatial mapping and predictive modeling of soil organic carbon stocks in Vermont agricultural lands using machine learning and environmental variables. *Computers and Electronics in Agriculture*, 237, 110727. <https://doi.org/10.1016/j.compag.2025.110727>
57. Zheng, F.L., Huang, C.H. and Norton, L.D., 2000. Vertical hydraulic gradient and run-on water and sediment effects on erosion processes and sediment regimes. *Soil Science Society of America Journal*, 64(1), pp.4–11. <https://doi.org/10.2136/sssaj2000.6414>



نشریه پژوهش‌های خاک

(علوم خاک و آب)

<https://srjournal.areeo.ir/>



مدل‌سازی مکانی شاخص‌های فرسایش‌پذیری خاک با استفاده از روش یادگیری ماشین و داده‌های مکانی چندمنبعی در دشت سیستان

ابوالفضل بامری^۱، فرهاد خرمالی^۱، فرشاد کیانی^۱، علی شهریاری^{۲*} و محمدرضا پهلوان راد^۳

^۱ گروه علوم مهندسی خاک، دانشکده مهندسی آب و خاک، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران.

^۲ گروه علوم مهندسی خاک، دانشکده مهندسی آب و خاک، دانشگاه زابل، زابل، ایران.

^۳ بخش تحقیقات خاک و آب، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان گلستان، سازمان تحقیقات، آموزش و ترویج کشاورزی، گرگان، ایران.

چکیده

اطلاعات مقاله

ارزیابی مخاطرات محیطی و مدیریت پایدار سرزمین، مستلزم شناخت دقیق فرسایش‌پذیری خاک است که این امر، بهره‌گیری از رویکردهای نوین در چارچوب نقشه‌برداری رقومی خاک را می‌طلبد. در این پژوهش، هدف مدل‌سازی مکانی شاخص‌های فرسایش‌پذیری آبی (K) و بادی (EF) در دشت سیستان با به‌کارگیری الگوریتم‌های یادگیری ماشین و سه گروه متغیر محیطی (خصوصیات خاک، شاخص‌های ژئومورفومتریک و داده‌های سنجش از دور) بوده است. بدین منظور، ۱۲۰۰ نمونه خاک سطحی گردآوری شد. در حالی که ضریب فرسایش‌پذیری آبی (K) بر اساس سه معادله تجربی متداول محاسبه شد، شاخص فرسایش‌پذیری بادی (EF) با استفاده از روش استاندارد تعیین گردید. سپس، این مقادیر نقطه‌ای با به‌کارگیری چهار الگوریتم یادگیری ماشین شامل جنگل تصادفی، کیوبیست، ماشین بردار پشتیبان و درخت رگرسیون، به نقشه‌های پیوسته مکانی تبدیل شدند. نتایج، نشان‌دهنده همبستگی منفی و معنی‌دار میان ضرایب K و شاخص EF است. همچنین، همبستگی منفی مشاهده‌شده میان شاخص‌های طیفی و درصد رس، برخلاف فرضیات اولیه، ناشی از تخریب پوشش گیاهی تحت تأثیر انباشت شوری در خاک‌های ریزبافت منطقه ارزیابی شد. حساسیت بالای معادلات K_{ShSm} و K_{EPIC} به متغیرهای بافتی در شرایط این منطقه، ضمن ایجاد سوگیری آماری، ضرورت واسنجی مجدد آن‌ها را آشکار ساخت. در پیش‌بینی مکانی EF، K_{EPIC} و K_{ShSm} مدل کیوبیست برتری داشت و برای K_{USLE} ، مدل جنگل تصادفی عملکرد بهتری نشان داد. در نهایت، یافته‌های این مطالعه بیانگر کارآمدی الگوریتم‌های یادگیری ماشین در نقشه‌برداری رقومی خاک برای مدل‌سازی مکانی فرسایش‌پذیری در مناطق خشک و کم‌ارتفاع نظیر دشت سیستان بوده و مبنایی برای توسعه روش‌های مشابه در مناطق همگون فراهم می‌آورد.

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۵/۰۳/۱۰

تاریخ بازنگری: ۱۴۰۵/۰۵/۰۹

تاریخ پذیرش: ۱۴۰۵/۰۵/۲۰

تاریخ انتشار: ۱۴۰۵/۰۶/۱۵

واژه‌های کلیدی

الگوریتم بوروتا

جنگل تصادفی

دشت سیلابی

فرسایش خاک

کیوبیست

نقشه‌برداری رقومی خاک

* ایمیل نویسنده مسئول

shahriari.ali@uoz.ac.ir

استناد: بامری، ا.، خرمالی، ف.، کیانی، ف.، شهریاری، ع.، پهلوان راد، م.ر.، ۱۴۰۵. مدل‌سازی مکانی شاخص‌های فرسایش‌پذیری خاک با استفاده از روش یادگیری ماشین و داده‌های مکانی چندمنبعی در دشت سیستان. مقاله پژوهشی، نشریه پژوهش‌های خاک، (۲)، ۴۰، ص ۲۳۵-۲۶۱.

DOI: <https://doi.org/10.22092/IJSR.2026.372940.820>

