

Digital Mapping of Soil Penetration Resistance and Shear Strength using Machine Learning Algorithms in the Kilane Watershed, Kurdistan Province

Farzaneh Parsaie¹ | Ahmad Farrokhian Firouzi^{1*}  | Masoud Davari² |
Ruhollah Taghizadeh-Mehrjardi³

1. Department of Soil Science and Engineering, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Ahvaz, Iran.
2. Department of Soil Science, Faculty of Agriculture, University of Kurdistan, Sanandaj, Iran.
3. Department of Geosciences, Soil Science and Geomorphology, University of Tübingen, Tübingen, Germany.
E-mail: a.farrokhian@scu.ac.ir

Article Info

Article type:
Research Article

Article history:
Received: 01 Sept. 2024
Revised: 13 Oct. 2024
Accepted: 29 Oct. 2024
Published online: 01 Mar. 2025

Keywords:
Digital mapping,
Environmental Variables,
Machine Learning,
Spatial Variability.

Abstract

The mechanical properties of soil, such as shear strength and penetration resistance, play a crucial role in enhancing agricultural production and soil resource management. The aim of this research was to generate digital maps of soil shear strength and penetration resistance using Gradient Boosted Decision Trees (XGBoost), Random Forest (RF), and k-Nearest Neighbors (k-NN) models in the Kielaneh watershed, located in Kurdistan Province, covering an area of 12,000 hectares. Penetration resistance and shear strength were measured using handheld penetrometers and vane shear devices at 150 observation points in the topsoil layer (0 to 10 cm). Spectral data and auxiliary variables extracted from the digital elevation model and Sentinel-2 satellite images, including CHND, VD, RSP, CHNBL, Brightness, WE, NDVI, Band 12, Greenness, and PLC, were utilized. Additionally, soil properties such as organic matter, lime content, bulk density, the geometric mean diameter of soil aggregates, soil texture components (percentages of clay, sand, and silt), and near-infrared soil spectroscopy data (LT) were incorporated as indicators of soil-forming factors to estimate soil shear strength and penetration resistance. The results showed that the XGBoost model outperformed the other models in predicting soil shear strength in the surface layer, achieving an R^2 of 0.61 and an nRMSE of 0.16. Similarly, it demonstrated the highest accuracy for predicting soil penetration resistance in the surface layer, with an R^2 of 0.60 and an nRMSE of 0.11. Overall, the XGBoost model, utilizing spectral data along with topographic variables and soil parameters, effectively estimated the spatial variability of soil mechanical properties with acceptable accuracy in the study area. The maps generated in this research can serve as practical templates for developing soil management strategies in national soil science studies.

Cite this article: Parsaie, F., Farrokhian Firouzi, A., Davari, M., Taghizadeh-Mehrjardi, R. (2025). Digital Mapping of Soil Penetration Resistance and Shear Strength using Machine Learning Algorithms in the Kilane Watershed, Kurdistan Province. *Journal of Range & Watershed Management*, 78 (1), 124-143. DOI: <http://doi.org/10.22059/jrwm.2024.381733.1783>



© The Author(s).

Publisher: University of Tehran Press

نقشه برداری رقومی مقاومت فروروی و برشی خاک با استفاده از الگوریتم‌های یادگیری ماشین در حوزه آبخیز کیلانه، استان کردستان

فرزانه پارسایی^۱ | احمد فرخیان فیروزی^{۱*} | مسعود داوری^۲ | روح‌الله تقی‌زاده مهرجردی^۳

۱. گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه شهید چمران اهواز، اهواز، ایران.

۲. گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه کردستان، سنندج، ایران.

۳. گروه علوم زمین، علوم خاک و ژئومرفولوژی، دانشگاه توبینگن، توبینگن، آلمان.

رایانامه: a.farrokhan@scu.ac.ir

اطلاعات مقاله

چکیده

نوع مقاله:

مقاله پژوهشی

تاریخ دریافت: ۱۴۰۳/۰۶/۱۱

تاریخ بازنگری: ۱۴۰۳/۰۷/۲۲

تاریخ پذیرش: ۱۴۰۳/۰۸/۰۸

تاریخ انتشار: ۱۴۰۳/۱۲/۱۱

کلیدواژه‌ها:

تغییرپذیری مکانی،

متغیرهای محیطی،

نقشه‌برداری رقومی،

یادگیری ماشین.

ویژگی‌های مکانیکی خاک، مانند مقاومت برشی و مقاومت فروروی، نقش مهمی در افزایش سطح تولید محصولات کشاورزی و مدیریت منابع خاک دارند. هدف از این پژوهش تهیه نقشه رقومی مقاومت برشی و فروروی خاک با استفاده از درخت تصمیم تقویت شده با گرایان (XGBoost)، جنگل تصادفی (RF) و مدل نزدیکترین k-همسایگی (k-NN) در حوزه آبخیز کیلانه واقع در استان کردستان با مساحت ۱۲ هزار هکتار بود. مقاومت فروروی و برشی با دستگاه‌های نفوذسنج دستی و برش‌پره‌ای در ۱۵۰ نقطه مشاهداتی لایه سطحی (۰ تا ۱۰ سانتی‌متری) خاک اندازه‌گیری شد. داده‌های طیفی و متغیرهای کمکی مستخرج از مدل رقومی ارتفاع و تصاویر ماهواره سنتینل-۲ شامل CHND، RSP، VD، CHNBL، Brightness، WE، NDVI، Band12، Greenness، PLC و ویژگی‌های خاک شامل ماده آلی، آهک، جرم مخصوص ظاهری، میانگین هندسی قطر خاکدانه‌ها، اجزاء بافت خاک (درصد رس، شن، سیلت) و داده‌های طیف سنجی نزدیک خاک (LT) به عنوان نمایندگان عوامل خاک‌سازی برای برآورد مقاومت برشی و فروروی خاک استفاده شد. نتایج نشان داد که مدل XGBoost برای پیش‌بینی مقاومت برشی خاک در لایه سطحی با R^2 برابر ۰/۶۱، nRMSE برابر ۰/۱۶ و مقاومت فروروی خاک در لایه سطحی با R^2 برابر ۰/۶۰، nRMSE برابر ۰/۱۱ نسبت به سایر مدل‌ها دارای دقت بیشتری بودند. به طور کلی مدل XGBoost با استفاده از داده‌های طیفی به همراه متغیرهای توپوگرافی و پارامترهای خاک توانستند تغییرپذیری مکانی و ویژگی‌های مکانیکی خاک را با صحت قابل قبول در منطقه مورد مطالعه برآورد نمایند. نقشه‌های تهیه شده در این پژوهش می‌توانند به عنوان الگویی کاربردی در تهیه نقشه‌های مدیریت پذیر خاک‌ها در مطالعات خاکشناسی کشور مورد استفاده قرار گیرند.

استناد: پارسایی، فرزانه، فرخیان فیروزی، احمد، داوری، مسعود، تقی‌زاده مهرجردی، روح‌الله (۱۴۰۴). مدل‌سازی رقومی مقاومت فروروی و برشی خاک با استفاده از الگوریتم‌های یادگیری ماشین در حوزه آبخیز کیلانه، استان کردستان. نشریه مرتع و آبخیزداری، ۷۸(۱)، ۱۲۴-۱۴۳.

DOI: <http://doi.org/10.22059/jrwm.2024.381733.1783>



© نویسندگان.

ناشر: انتشارات دانشگاه تهران.

۱. مقدمه

کاربری اراضی یکی از مهم‌ترین روش‌های دخالت انسان در فرآیندهای طبیعی است که می‌تواند تأثیر عمده‌ای بر کیفیت و پایداری خاک داشته باشد (عبداللهی و همکاران، ۲۰۱۳). از سویی مدیریت خاک نقش مهمی را در کشاورزی پایدار و محیط زیست ایفا می‌کند. مدیریت زراعی مانند مدیریت خاکورزی، روش‌های آبیاری و کود دهی بر ویژگی‌های فیزیکی، مکانیکی و شیمیایی خاک اثر دارد (خسروانی و همکاران، ۲۰۲۱). مقاومت برشی و مقاومت فروروی دو ویژگی مکانیکی کلیدی هستند که تأثیر زیادی بر کیفیت و کارایی خاک دارند. این ویژگی‌ها به طور مستقیم بر پایداری سازه‌ها، عملیات کشاورزی، و عملکرد خاک در برابر نیروهای خارجی تأثیر می‌گذارند (Khosravani et al., 2023).

مقاومت برشی لایه رویی خاک می‌تواند همانند مقاومت اصطکاکی^۱ ناشی از لغزیدن ذرات روی همدیگر، حرکت غلتک مانند بین دانه‌های مجاور و قفل شدن دانه‌ها در یکدیگر باشد. همچنین پیوندهای شیمیایی بین ذرات رس خاک باعث چسبندگی و مقاومت در برابر نیرو و تنش وارده می‌گردد (Kang et al., 2021). مقاومت برشی لایه رویی خاک تحت تأثیر ویژگی‌های متفاوتی از خاک مانند شیمی کانی‌ها و کلوئیدها یا مواد آلی که بر چسبندگی خاکدانه‌ها اثر می‌گذارند، می‌باشد. اندازه، شکل و ساختمان ذرات و خاکدانه‌ها مقاومت اصطکاکی خاک را تحت تأثیر قرار می‌دهند و وجود شبکه ریشه‌ها ساختار بزرگتری از خاکدانه‌ها را تشکیل می‌دهند (Khosravani et al., 2021; Al-Adhahd et al., 2021). براساس پژوهش‌های گذشته در زمینه فرسایش خاک، در شرایطی که جریان‌های شیاری به حد آستانه فرساینده خود می‌رسند، مقاومت برشی می‌تواند به طور مستقیم بر میزان فرسایش تأثیر بگذارد. همچنین فرآیند جداسازی ذرات به وسیله قطرات باران به مقاومت برشی لایه رویی خاک وابسته است (Bachmann et al., 2006).

افزایش مقاومت فروروی خاک به عواملی مانند تراکم خاک، بافت خاک، رطوبت، محتوای مواد آلی، وجود لایه‌های سخت زیرین و افزودن پلیمرها بستگی دارد. مدیریت صحیح این عوامل می‌تواند به بهبود ویژگی‌های مکانیکی خاک و در نتیجه بهینه‌سازی عملکرد کشاورزی و پایداری خاک کمک کند (Machado et al., 2023). مقاومت فروروی خاک می‌تواند تأثیر زیادی بر جذب آب و حرکت آن در خاک داشته باشد. خاک‌هایی با مقاومت فروروی بالا ممکن است آب را کمتر جذب کنند و نیاز به مدیریت ویژه‌ای داشته باشند (Kunakh et al., 2022; Soil Science Society of America, 2008). بنابراین با توجه به اهمیت این دو ویژگی مکانیکی خاک، شناخت رفتار خاک نیاز به درک صحیحی از الگوی تغییرپذیری این ویژگی‌ها دارد. اطلاع از تغییرپذیری ویژگی‌های خاک و تهیه نقشه آن‌ها برای کشاورزی دقیق و تولید پایدار ضروری است (Brevik et al., 2015).

طیف‌سنجی خاک^۲ یکی از روش‌های سنجش از نزدیک است. طیف‌سنجی یعنی تهیه منحنی‌های انعکاس طیفی^۳ پدیده یا پدیده‌های موردنظر در گستره طول‌موج‌هایی مشخص می‌باشد (Schneider & Young, 1997). منحنی‌های انعکاس طیفی خاک می‌تواند بسیاری از محدودیت‌های آزمایشگاهی را برطرف نماید، زیرا خلاف روش‌های مرسوم اندازه‌گیری ویژگی‌های خاک در آزمایشگاه، داده‌های خاک در رویکرد طیفی با یک روش استاندارد و تنها در یک مرحله بدون نیاز به مواد شیمیایی گران‌قیمت و سمی تعیین می‌گردند. بنابراین خطای ناشی از روش‌های گوناگون اندازه‌گیری و شخص کاربر به‌طور قابل‌توجهی کاهش می‌یابد (Babaeian et al., 2015). استفاده از بازتاب طیفی خاک در طول‌موج‌های بین ۳۵۰ تا ۲۵۰۰ نانومتر در دامنه‌های طیفی مرئی (Vis) و مادون‌قرمز نزدیک (NIR) به‌عنوان جایگزین روش‌های آزمایشگاهی به‌کار برده می‌شوند (Janik et al., 2009). از این‌رو می‌توان از انعکاس طیفی خاک مشابه با توابع انتقالی خاکی^۴ برای پیش‌بینی ویژگی‌های خاک استفاده کرد و توابع جدیدی تحت عنوان توابع انتقالی طیفی^۵ ایجاد کرد. طبق تحقیقاتی که انجام شده

1 Shear Strength

2 Soil Spectroscopy

3 Proximal spectral reflectance

4 Pedotransfer functions

5 Spectra pedotransfer functions

استفاده از طیف‌سنجی خاک می‌تواند بسیاری از محدودیت‌های توابع انتقالی خاکی را برطرف نماید، زیرا در طیف‌سنجی متغیرهای ورودی توابع تنها داده‌های طیفی خاک هستند که بر خلاف ویژگی‌های زودیافت خاک، در یک مرحله و با یک روش استاندارد اندازه‌گیری می‌شوند (Babaeian et al., 2015). سان^۱ و همکاران (۲۰۲۳) طی پژوهشی دقت نقشه‌برداری خاک را برای ۱۳۲ پروفیل خاک بررسی کردند. در این پژوهش سه دسته داده شامل: داده‌های خاک اندازه‌گیری شده، ترکیب داده‌های اندازه‌گیری شده خاک و سنجش از دور و ترکیب داده‌های اندازه‌گیری شده خاک و داده‌های طیف‌سنجی را برای تهیه نقشه خاک استفاده کردند. نتایج نشان داد که استفاده از داده‌های خاک به همراه داده‌های طیف‌سنجی خاک به عنوان متغیرهای محیطی ۵۰٪ دقت پیش‌بینی مدل را نسبت به استفاده منفرد از داده‌های خاک (مانند ماده آلی، pH، CEC، سیلت) بیشتر کرد و همچنین دقت پیش‌بینی را نسبت به استفاده از ترکیب داده‌های خاک و سنجش از دور ۳۰٪ افزایش داد. در مطالعه‌ای دیگر که توسط ژائو^۲ و همکاران (۲۰۲۴) از داده‌های طیف‌سنجی و متغیرهای محیطی برای بهبود پیش‌بینی شوری و قلیائیت خاک استفاده کردند. نتایج این پژوهش نشان داد که ترکیب داده‌های طیف‌سنجی با متغیرهای محیطی به‌طور قابل توجهی دقت پیش‌بینی شوری و قلیائیت خاک را افزایش داد.

الگوریتم‌های یادگیری ماشین به‌عنوان بخشی از دانش هوش مصنوعی در عصر فناوری و اطلاعات به‌طور فزاینده‌ای در زمینه‌های مختلف علمی به ویژه نقشه‌برداری رقومی خاک^۳ (DSM) توسعه یافته است (Hengl et al., 2018; Minasny & McBratney, 2016; Mousavi et al., 2021^a). یکی از کاربردهای عمده الگوریتم‌های یادگیری ماشین عمدتاً شناسایی و پیش‌بینی الگوهای موجود در چندین مجموعه داده بزرگ حاصل داده‌های ماهواره‌ای یا پارامترهای مشتق شده از مدل رقومی ارتفاع^۴ (DEM) است. این داده‌ها به‌عنوان کنترل‌کننده‌ها یا پیش‌بینی‌کننده‌های محیطی که نماینده فاکتورهای خاکسازي هستند نقش دارند (Padarian et al., 2020; Hengl et al., 2018). در همین راستا مندس^۵ و همکاران، (۲۰۲۳) گزارش کرده‌اند که الگوریتم‌های یادگیری ماشین (MLM) برای تهیه نقشه‌ی ویژگی‌های خاک در اراضی کشاورزی با تعداد نمونه کمتر نسبت به روش‌های زمین آماری کارا تر هستند.

از روش‌های MLM برای برآورد ویژگی‌های فیزیکی‌شیمیایی و مکانیکی خاک، برای مثال مدل XGboost برای مدل‌سازی مکانی کربن آلی خاک (SOC^۶) (نگوین^۷ و همکاران، ۲۰۲۲؛ ژانگ^۸ و همکاران، ۲۰۲۲؛ محمودزاده^۹ و همکاران، ۲۰۲۰) و مقاومت فروروی خاک (کوین^{۱۰} و همکاران، ۲۰۲۳، مومنی و همکاران، ۲۰۲۳)، مدل جنگل تصادفی (RF^{۱۱}) برای هدایت هیدرولیکی اشباع خاک (رضایی و همکاران، ۲۰۲۳)، مدل‌سازی مکانی SOC (متین‌فر و همکاران، ۲۰۲۱؛ موسوی و همکاران، ۲۰۲۲)، رگرسیون بردار پشتیبان (SVR^{۱۲}) در برآورد شوری خاک (تقی‌زاده مهرجردی و همکاران، ۲۰۲۱؛ موسوی و همکاران، ۲۰۲۱ ب)، و مدل k-NN برای برآورد برخی ویژگی‌های خاک سطحی (خالدیان و میلر، ۲۰۲۰) و عناصر غذایی خاک استفاده شده است (Parsaie et al., 2021; Gao et al., 2019). علی‌رغم مطالعات صورت پذیرفته اما پژوهش‌های اندکی در زمینه مدل‌سازی ویژگی‌های مکانیکی خاک مانند مقاومت فروروی و برشی با لحاظ نمودن داده‌های طیف سنجی نزدیک بویژه در مناطقی مشابه حوضه آبخیز کیلانه واقع در استان کردستان با تغییرات و تنوع توپوگرافی زیاد انجام شده است.

1 Sun

2 Zhao

3 Digital Soil Mapping

4 Digital Elevation Model

5 Mendes

6 Soil Organic Carbon

7 Nguyen

8 Zhang

9 Mahmoudzadeh

10 Qin

11 Random Forest

12 Support Vector Regression

اصغری و همکاران (۲۰۲۴) برای برآورد مقاومت فروروی از ویژگی‌های زودیاقت خاک از مدل‌های رگرسیون خطی چندگانه (MLR^1)، شبکه عصبی مصنوعی (ANN^2) و برنامه‌ریزی بیان ژن (GEP^3) استفاده کردند. نتایج این مدل‌سازی نشان داد که رطوبت خاک مزرعه، سیلت و جرم مخصوص ظاهری نسبی، مهمترین متغیرهای ورودی در برآورد مقاومت فروروی خاک بودند. همچنین ارزیابی مدل‌ها نشان داد که ANN از بیشترین دقت و مدل MLR از کمترین دقت در برآورد مقاومت فروروی خاک برخوردار بود. خسروانی و همکاران (۲۰۲۱) به بررسی تأثیر نوع کاربری اراضی و واحدهای فیزیوگرافی بر مقاومت فروروی و برشی خاک و تغییرپذیری مکانی این ویژگی‌ها در خاک‌های دشت لپویی استان فارس پرداختند. برای بررسی تغییرپذیری ویژگی‌های مورد مطالعه از سه تخمین‌گر کوکریجینگ، کریجینگ-معمولی و وزن‌دهی عکس فاصله استفاده شد. روش کوکریجینگ برای برآورد مقاومت برشی و فروروی بر اساس آماره ضریب تبیین (R^2) با مقادیر ۰/۵۵ و ۰/۳۸ عملکرد مناسب‌تری داشت. به‌طور کلی روش‌های زمین آماری از دقت متوسطی در پیش‌بینی مقاومت فروروی و برشی خاک برخوردار بودند. هوائی و همکاران (۲۰۱۴) به پیش‌بینی مقاومت برشی خاک سطحی و رتبه‌بندی مهمترین فاکتورهای مؤثر بر آن، با استفاده از مدل‌سازی توسط روش‌های شبکه عصبی مصنوعی (ANNs) و رگرسیون خطی چندگانه (MLR) و مقایسه این دو روش پرداختند. نتایج نشان‌دهنده دقت مناسب روش ANNs نسبت به روش MLR به دلیل توانایی زیاد شبکه عصبی در کشف و بررسی روابط پیچیده غیرخطی بین پارامترها است. ژو^۴ و همکاران (۲۰۲۲) در مطالعه‌ای برای پیش‌بینی پارامترهای مقاومت برشی خاک (چسبندگی و زاویه اصطکاک داخلی) با ترکیب داده‌های آزمایش نفوذسنج مخروطی (CPT^5) و ویژگی‌های خاک از سه الگوریتم یادگیری ماشین شامل شبکه عصبی پیش‌انتشار (BPNN)^۶، رگرسیون حداقل مربعات جزئی (PLSR)^۷ و رگرسیون بردار پشتیبان (SVR)^۸ استفاده کردند. نتایج نشان داد که در میان همه مدل‌های ارزیابی‌شده، مدل BPNN مناسب‌ترین مدل برای پیش‌بینی چسبندگی خاک بود و مدل SVR بهترین عملکرد را در پیش‌بینی زاویه اصطکاک داخلی خاک داشت. اصغری و همکاران (۲۰۱۷) گزارش کردند ضریب تغییرات (CV^9) مقاومت فروروی در ۱۰۵ نمونه خاک برداشته شده (با فواصل ۳۰۰۰ متر) از اراضی زراعی دشت اردبیل (۴۲×۲۴ km) حدود ۵۰ درصد تعیین گردید و دامنه تغییرات کربن آلی از ۰/۳ تا ۲/۴ درصد، جرم مخصوص ظاهری از ۱/۰۲ تا ۱/۶۳ گرم بر سانتیمتر مکعب و مقاومت فروروی از ۱/۱ تا ۶/۶ مگاپاسکال به دست آمد. همچنین اصغری و شهابی (۲۰۱۹) مقادیر CV را برای مقاومت فروروی خاک در اراضی زراعی و بایر بخش شندآباد منطقه شبستر حدود ۴۶ درصد گزارش نمودند.

در این پژوهش تلاش بر این است که از مدل‌های پیش‌بینی کننده MLM همراه با متغیرهای محیطی و داده‌های طیف‌سنجی نزدیک برای افزایش دقت در نقشه‌برداری رقومی دو ویژگی مکانیکی مقاومت برشی و مقاومت فروروی استفاده شود. بدین منظور از داده‌های انعکاس طیفی خاک در گستره مرئی-مادون قرمز نزدیک برای برآورد مقاومت فروروی و مقاومت برشی خاک حوزه آبخیز کیلانه واقع در استان کردستان با کاربری‌های مختلف استفاده شد. در این پژوهش اهداف ذیل تعریف گردیدند که شامل: ۱- تهیه نقشه رقومی دو ویژگی مکانیکی خاک شامل مقاومت برشی و مقاومت فروروی و ۲- مقایسه کارایی سه الگوریتم یادگیری ماشین شامل: درخت تصمیم تقویت شده با گرادیان (XGBoost)، جنگل تصادفی (RF) و مدل نزدیکترین k-همسایگی (k-NN) در معرفی یک مدل مکانی مناسب برای پیش‌بینی ویژگی‌های مکانیکی خاک مورد مطالعه ۳- معرفی مهمترین فاکتورهای محیطی در پیش‌بینی ویژگی‌های خاک و ۴- بررسی کارایی داده‌های سنجش از نزدیک در پیش‌بینی ویژگی‌های مکانیکی خاک در حوزه آبخیز کیلانه در غرب ایران.

1 Multiple Linear Regression

2 Artificial Neural Network

3 Gene Expression Programming

4 Zhu

5 Cone Penetration Test

6 Bckpropagation Neural Network

7 Partial Least Squares Regression


8 Support Vector Regression

9 Coefficient of Variation

۲. مواد و روش‌ها

۲-۱. منطقه مورد مطالعه

منطقه مورد مطالعه حوضه آبخیز کیلانه واقع در استان کردستان با مساحت ۱۲ هزار هکتار و متوسط ارتفاع ۱۸۵۵ متر از سطح دریای آزاد است (شکل ۱). حوزه مورد بررسی در موقعیت جغرافیائی ۴۶ درجه و ۴۶ دقیقه و ۱۲/۸ ثانیه تا ۴۶ درجه و ۵۶ دقیقه و ۸ ثانیه طول شرقی و ۳۵ درجه و ۱۲ دقیقه و ۳/۸ ثانیه تا ۳۵ درجه و ۲۱ دقیقه و ۸/۱ ثانیه عرض شمالی قرار دارد (شکل ۱). در مجموع ۱۱۷۹۵/۳۰۶ هکتار معادل ۹۷/۸۴۰ درصد از کل حوزه مورد مطالعه را اراضی کوهستانی و تپه تشکیل داده‌اند و ۲۶۰/۳۵۶ هکتار معادل ۲/۱۶۰ درصد حوزه شامل زمین‌های متفرقه است که از چشمه‌ها و آبراهه‌ها تأمین آب می‌شوند و بعضی از قسمت‌های اراضی تپه ماهور نیز به صورت زراعت آبی و باغات مورد بهره‌برداری قرار گرفته است. ۱۶۳ هکتار از این اراضی را باغات، ۱۳۴ هکتار بیرون زدگی سنگی، ۸۴۳۸ هکتار از این اراضی را مرتع، ۴۴ هکتار را مناطق مسکونی، ۳۲۸ هکتار را زراعت آبی و ۲۹۴۸ هکتار را زراعت دیم به خود اختصاص داده‌اند. این منطقه با متوسط درجه حرارت سالیانه هوای ۱۰ درجه سانتی‌گراد و میانگین بارندگی سالیانه ۵۰۹ میلی‌متر در دوره آماری ۲۰ ساله (۱۳۷۹-۱۳۹۹) به همراه پردازش داده‌های اقلیمی در نرم‌افزار JNSM^۱ به‌ترتیب دارای رژیم رطوبتی زیریک^۲ و رژیم حرارتی مزیک^۳ است (Banaie, 1998). واحدهای سیمای اراضی کوه‌ها و تپه‌ها اصلی‌ترین واحدهای فیزیوگرافی منطقه می‌باشند. خاک‌های مورد مطالعه بر اساس رده‌بندی آمریکایی خاک‌ها (کارکنان بررسی خاک^۴، ۲۰۲۲) در دو رده اینسپتی سول^۵ و انتی سول^۶ قرار دارند. این منطقه دارای تغییرات ارتفاعی معنی‌دار است که شیب‌های بیش از ۳۰٪ را شامل می‌شود و اصولاً از کوهستان‌ها و تپه‌ها تشکیل شده است.



شکل ۱. موقعیت الف) حوزه آبخیز کیلانه نسبت به کشور ایران در ایران ب) در استان کردستان پ) و توزیع مکانی نمونه‌های خاک

- 1 Java Newhall Simulation Model
- 2 Xeric
- 3 Thermic
- 4 Soil Science Society of America
- 5 Inceptisols
- 6 Entisols

۲-۲. تهیه و اجرای پایگاه داده‌ها

در این پژوهش موقعیت نمونه‌های خاک سطحی (عمق صفر تا ۱۰ سانتی‌متر) مورد نظر با استفاده از روش نمونه‌برداری مکعب لاتین مشروط ($CLHS^1$) جهت تعیین محل نقاط نمونه‌برداری که از اواسط ماه مرداد تا اواسط آبان ادامه یافت، محل ۱۵۰ نقطه مشاهداتی با سیستم موقعیت‌یاب جهانی^۲ برداشت گردید (شکل ۱). متغیرهای محیطی مورد استفاده در روش نمونه‌برداری مکعب لاتین مشروط شامل ۸ لایه رقومی: ارتفاع، شیب، عمق دره، تاثیر باد، شاخص خیس، فاصله از کانال آبراهه، سطح پایه کانال آبراهه و شدت تابش پخشیده بودند. دو ویژگی مکانیکی مقاومت برشی خاک سطحی به وسیله مقاومت‌سنج برش پره‌ای و مقاومت فروروی به کمک دستگاه نفوذسنج دستی اندازه‌گیری شد. پس از هوا خشک کردن نمونه‌ها، کوبیدن و عبور از الک ۲ میلی‌متری، بخشی از نمونه‌های خاک برای تجزیه‌های آزمایشگاهی و بخش دیگری از آن‌ها برای مطالعه‌های طیف‌سنجی خاک استفاده گردید.

۲-۳. بازتاب طیفی نمونه‌های خاک

بازتاب طیفی نمونه‌های خاک مورد بررسی به وسیله دستگاه اسپکترومتر زمینی (FieldSpec @3, ASD, FR, USA) آزمایشگاه خاکشناسی دانشگاه تربیت مدرس اندازه‌گیری شد. بدین منظور نمونه خاک دست خورده حدود ۶۰ گرم خاک هوا خشک که از الک ۲ میلی‌متری عبور داده شده در یک پتری دیش با قطر ۱۰ سانتی‌متر و ضخامت یک سانتی‌متر گذاشته شد. سپس منحنی‌های طیفی آن‌ها در دامنه‌های مرئی - مادون قرمز نزدیک و میانی (۳۵۰-۲۵۰۰ نانومتر) با روش‌های استاندارد طیف‌سنجی در تاریک‌خانه در چند تکرار برای هر نمونه خاک انجام گردید (Viscarra Rossel, 2008).

با استفاده از نرم‌افزار RS3 بر روی رایانه قابل حمل متصل به دستگاه اسپکترومتر، منحنی بازتاب طیفی نمونه‌ها ثبت شد. به طور میانگین از هر نمونه ۵ قرائت بازتاب متوالی ثبت گردید. با استفاده از نرم‌افزار ViewSpec یک میانگین به ازای تکرارهای مختلف برای هر نمونه خاک، محاسبه شد. سپس این منحنی‌ها به شکل فایل‌های متنی و کتابخانه‌های طیفی ذخیره گردیدند. به جهت وجود آشفتگی‌های طیفی زیاد در طول موج‌های ۴۰۰-۳۵۰ و ۲۵۰۰-۲۴۵۱ نانومتر، این بازه از تمامی طیف‌ها حذف و در مدل‌سازی استفاده نمی‌شود (Gomez et al., 2008). همچنین، برای حذف این آشفتگی‌ها در طیف‌های خاک (همچون رفتار غیرخطی باندها، فیلتر، بارزسازی طیفی و نرمال‌سازی طیف‌ها) و همچنین ارتقای کیفی داده‌ها، روش‌های گوناگون پیش‌پردازش با نرم‌افزار Parles ۳/۱ بر روی داده‌های طیفی انجام گردید. هدف اصلی از پیش‌پردازش داده‌های طیفی، حذف عوامل خارجی و استفاده مؤثر از داده‌های طیفی هنگام فرآیند تخمین است. بر اساس روش اعتبارسنجی متقابل و بررسی دقیق نتایج، از انواع روش‌های پیش‌پردازش شامل فیلتر میانه، فیلتر ساویتزکی گُلای^۳، نرمال‌سازی بر اساس میانگین، متغیر نرمال استاندارد (SNV^4)، تصحیح پخشیده چندگانه (MSC^5)، مشتق اول همراه فیلتر ساویتزکی و گُلای و مشتق دوم به همراه فیلتر ساویتزکی و گُلای برای پیش‌پردازش داده‌های طیفی خاک استفاده شد و بهترین روش فیلتر ساویتزکی گُلای مشتق اول انتخاب گردید.

۲-۴. متغیرهای محیطی

متغیرهای محیطی مورد استفاده در این مطالعه شامل مدل رقومی ارتفاع با قدرت تفکیک مکانی ۱۲/۵ متر است که از ماهواره آلوس پالسار^۶ (۲۰۱۱) در سیستم مختصات جغرافیایی (WGS84) به دست آمده است و متغیرهای ژئومورفومتریک با استفاده از نرم‌افزار SAGA

1 Conditional Latin Hypercube Sampling

2 Global position system

3 Savitzky - Golay

4 Standard Normal Variate

5 Multiplicative Signal Correction

6 Alos Palsar

GIS 7.3 تهیه شدند. پارامترهای سنجش از دور نیز از تصاویر ماهواره‌ای سنتینل ۲ با پوشش ابری کمتر از ۹٪ در ماه‌های مرداد، شهریور و مهر ۱۴۰۱ به دست آمدند. در این تحقیق برای انتخاب بهینه‌ترین دسته داده از میان متغیرهای محیطی پیش‌بینی کننده ویژگی‌های مکانیکی خاک از روش حذف ویژگی برگشتی (RFE)^۱ در بسته "caret" استفاده شد (Demir & Şahin, 2021).

۲-۵. مجموعه داده‌ها

به صورت تصادفی ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد برای ارزیابی مدل‌ها تقسیم گردیدند. درجه اهمیت هریک از متغیرهای محیطی در الگوریتم یادگیری ماشین مورد استفاده طبق تابع اهمیت متغیر (varImp) در بسته "caret" انجام گردید. همچنین جهت به دست آوردن پایداری نتایج در برازش مدل‌ها از رویکرد ۱۰ گام ۱۰ تکرار استفاده گردید.

۲-۶. مدل‌سازی مکانی

سه الگوریتم جنگل تصادفی (RF)، مدل نزدیکترین k-همسایگی (k-NN) و درخت تصمیم تقویت شده با گرادیان (XGBoost) با استفاده از بسته‌های تخصصی Random Forest، caret و xgbTree کدنویسی در نرم افزار R-studio نسخه ۴،۱،۱ برای پیش‌بینی توزیع مکانی مقاومت برشی و مقاومت فروروی مورد استفاده قرار گرفت. شایان ذکر است مدل‌سازی ویژگی‌های مکانیکی خاک در دو سناریو انجام شد. در سناریو اول، مدل‌سازی بر اساس متغیرهای محیطی و در سناریو دوم، مدل‌سازی بر اساس متغیرهای محیطی انتخاب‌شده، داده‌های طیفی و داده‌های خاک انجام شد.

۲-۶-۱. الگوریتم جنگل تصادفی

جنگل تصادفی که توسط بریمن^۲ (۲۰۰۱) توسعه یافته است، یک الگوریتم یادگیری ماشین است که به طور گسترده برای طبقه‌بندی و رگرسیون استفاده می‌شود. یک درخت تصمیم منفرد به دلیل واریانس و سوگیری بالای آن طبقه‌بندی و رگرسیون ضعیفی را ارائه می‌دهد. در حالی که RF تمایل به تولید مدل‌های قوی دارد زیرا می‌تواند مشکلات یاد شده را با استفاده از مجموعه‌ای از درختان کاهش دهد. RF هزاران درخت دوتایی تصادفی را برای ایجاد جنگل تصادفی تولید می‌کند. هر درخت براساس یک نمونه بوت استرپ، با استفاده از روش درختان طبقه‌بندی و رگرسیون (CART) با زیرمجموعه تصادفی از متغیرهای انتخاب شده در هر گره رشد می‌کند. برای هر درختی که بر روی یک نمونه بوت استرپ رشد می‌کند، نرخ خطای خارج از کیسه (OOB^۳) با استفاده از مشاهدات خارج از بوت استرپ محاسبه می‌شود. برای اجرای مدل RF کاربر باید دو پارامتر پیش‌بینی، تعداد درختان در جنگل (ntree) و تعداد متغیرهای قابل استفاده در انتهای هر گره (mtry) را بهینه کند تا خطای OOB را به حداقل برساند و عملکرد مدل خوبی را به دست آورد (Matthew, 2011).

۲-۶-۲. الگوریتم نزدیکترین k-همسایگی

نزدیکترین احتمال وقوع و تعیین مقدار پیش‌بینی صورت گرفته در این مدل بر اساس بهینه‌ترین k همسایگی ایجادشده در مجاورت نمونه پیش‌بینی شده و حداقل مربعات خطا (RMSE) تعیین می‌گردد (کاراموز و عراقی‌نژاد، ۲۰۰۵). در این تحقیق جهت تعیین ارزش نمونه‌های جدید در مناطق فاقد مشاهده در هر یک از نقاط مورد مطالعه، مقادیر k های ۵، ۷ و ۹ با هدف لحاظ نمودن حداکثر احتمالات ممکن در تعیین مقادیر متغیر هدف استفاده گردید.

1 Recursive Feature Elimination

2 Breiman

3 Out of the Bag

۲-۶-۳. الگوریتم درخت تصمیم تقویت شده با گرادیان^۱

درخت تصمیم تقویت شده با گرادیان یک الگوریتم یادگیری ماشینی بسیار موثر و پرکاربرد است. XGBoost یک سیستم تقویت کننده درختی است که به طور گسترده توسط دانشمندان داده برای دستیابی به نتایج پیشرفته در بسیاری از چالش‌های یادگیری ماشینی استفاده می‌شود (Chen & Guestrin, 2016).

۲-۷. ارزیابی عملکرد مدل‌ها

به منظور ارزیابی عملکرد هر یک از MLMs مورد استفاده از چهار شاخص آماری ضریب تبیین (R^2) و ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE) و ریشه میانگین مربعات خطای نرمال شده (nRMSE) استفاده گردید.

$$RMSE = \sqrt{\frac{1}{n} \sum (P_i - O_i)^2} \quad \text{(رابطه ۱)}$$

$$R^2 = 1 - \frac{\sum (O_i - P_i)^2}{\sum (O_i - \bar{O}_i)^2} \quad \text{(رابطه ۲)}$$

$$nRMSE = \frac{RMSE_{(i)}}{\bar{O}_i} \quad \text{(رابطه ۳)}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n (P_i - O_i) \quad \text{(رابطه ۴)}$$

که در آن P_i : مقادیر پیش‌بینی شده، O_i : مقادیر اندازه‌گیری شده، $\bar{O}_i$ میانگین مقادیر اندازه‌گیری شده و n تعداد مشاهدات است.

۳. نتایج و بحث

۳-۱. تجزیه و تحلیل آماری


آمار توصیفی ویژگی‌های خاک (عمق ۰-۱۰ سانتی‌متری) برای ۱۵۰ نمونه خاک در جدول (۱) ارائه شده است. در این جدول میانگین، انحراف معیار، میانه، مقادیر حداکثر، حداقل و ضریب تغییرات برای ویژگی‌های مقاومت برشی و مقاومت فروروی آمده است. میانگین مقاومت برشی و مقاومت فروروی به ترتیب ۲۱/۸۵ و ۳/۱۷ کیلوپاسکال است. همچنین، مقادیر حداقل و حداکثر مقاومت برشی و مقاومت فروروی به ترتیب ۵/۴۷ تا ۴۹/۲۱ کیلوپاسکال و ۰/۶۴ تا ۶/۸۸ کیلوپاسکال است که حاکی از تفاوت هر یک از مقادیر مقاومت‌ها در کاربری‌ها و واحدهای فیزیوگرافی مختلف در منطقه است (Alhai et al., 2021). بر اساس طبقه‌بندی متغیرهای با ضریب تغییرات کمتر از ۱۵ درصد دارای تغییرات کم، متغیرهای با تغییرات متوسط دارای ضریب تغییرات ۱۵-۳۵ درصد و متغیرهای با ضریب تغییرات بیش از ۳۵ درصد دارای تغییرات زیاد می‌باشند (Wilding & Dress, 1983). ضریب تغییرات معیاری از تغییرپذیری نسبی است و بر اساس این تقسیم‌بندی ضریب تغییرات مقاومت فروروی و مقاومت برشی با بیشترین ضریب تغییرات دارای کلاس تغییرپذیری زیاد می‌باشند. از دلایل زیاد بودن ضریب تغییرات در منطقه می‌توان به وضعیت مدیریت زراعی اشاره کرد (Monroy-Rodríguez et al., 2017). خلیل مقدم و همکاران (۲۰۱۱) بیان کردند که مقاومت برشی لایه رویی خاک در مراتع و مراتع تخریب شده دارای تغییرپذیری زیادی است که می‌تواند به دلیل تغییرات خاکدانه‌ها در گروه‌های بافتی مختلف و کاربری‌های متفاوت باشد. بررسی داده‌های مقاومت فروروی و مقاومت برشی نشان داد که حداکثر مقاومت فروروی و برشی در نقاط مختلف منطقه مورد مطالعه متفاوت است که می‌تواند به دلیل تغییر در

ویژگی‌های فیزیکی و شیمیایی خاک و همچنین تغییر کاربری اراضی باشد.

جدول ۱. آمار توصیفی مقاومت فروروی و مقاومت برشی خاک ($n=150$)

ویژگی‌های خاک	واحد	حداقل	حداکثر	میانگین	میانه	انحراف معیار	ضریب تغییرات (%)
مقاومت برشی	کیلوپاسکال	۵/۴۷	۴۹/۲۱	۲۱/۸۵	۲۰/۵۱	۸/۸۲	۰/۴۰
مقاومت فروروی	کیلوپاسکال	۰/۶۴	۶/۸۸	۳/۱۷	۲/۹۷	۱/۳۹	۰/۴۴

در شکل ۲ میانگین منحنی‌های خام خاک‌های مورد مطالعه با مقادیر بازتاب طیفی در هر طول موج، از گستره ۲۴۰۰-۴۰۰ نانومتر ارائه شده است. با توجه به این شکل منحنی داده‌های خام طیفی دارای یک برآمدگی در طول موج‌های ۵۰۰ تا ۶۰۰ نانومتر و همچنین چهار مشخصه جذبی در طول موج‌های ۱۴۰۰، ۱۹۰۰ و ۲۲۰۰ و ۲۳۴۰ نانومتر می‌باشند. شایان ذکر است که این مشخصه‌های جذبی در منحنی‌های حذف پیوستار بصورت بارزتری دیده می‌شود. پژوهش‌ها نشان داده‌اند که این مشخصه‌های جذبی مربوط به وجود آب آزاد و هیگروسکوپیک (۱۴۱۴ و ۱۹۱۵ نانومتر) و پیوند گروه‌های عاملی OH با فلزات آلومینیوم و منیزیم موجود در شبکه کانی‌های رسی (۲۲۱۲ نانومتر) در شبکه کانی‌های رس می‌باشد (Shahabi et al., 2022; Davari et al., 2021). از جمله عواملی که بر بازتاب طیفی تاثیر می‌گذارد، می‌توان به رنگ خاک، رطوبت خاک، مقدار ماده آلی، کربنات کلسیم و توزیع اندازه ذرات اشاره کرد. معمولاً افزایش کربنات کلسیم باعث افزایش در انعکاس طیفی خاک‌ها و همچنین افزایش عمق تعقر طیف‌ها می‌شود. مشخصه‌های جذبی مجاور طول موج ۲۳۳۸ نانومتر نشان‌دهنده وجود گروه‌های کربناتی در کانی‌های کربناته است (Gomez et al., 2008)، که نمونه‌های بررسی شده نیز گویای این مهم می‌باشد. همچنین عسگری و همکاران (۲۰۲۰) و خیامیم و همکاران (۲۰۱۵) نیز طول موج ۲۳۳۸ نانومتر را مشخصه کربنات‌ها معرفی کرده‌اند.



شکل ۲. میانگین منحنی‌های خام بازتاب

۳-۲. عملکرد مدل‌سازی

برای هر کدام از ویژگی‌های مکانیکی خاک مدل‌سازی در دو سناریو انجام شد. در سناریو اول مدل‌سازی بر اساس متغیرهای محیطی و در سناریو دوم مدل‌سازی بر اساس متغیرهای محیطی انتخاب‌شده، داده‌های طیفی و داده‌های خاک برای هر مدل انجام شد. عملکرد سه الگوریتم یادگیری ماشین (XGBoost، RF و KNN) برای پیش‌بینی مقاومت برشی و مقاومت فروروی در جدول ۲ ارائه شده است. نتایج مدل‌سازی نشان داد که مدل XGBoost برای سناریو ۲ توانست به طور دقیق مقاومت برشی و مقاومت فروروی را با کمترین RMSE و nRMSE (۳/۵۹، ۰/۱۶)، (۰/۳۶، ۰/۱۱) و بالاترین R^2 (۰/۶۱، ۰/۶۰) به ترتیب در منطقه مطالعاتی پیش‌بینی کند (جدول ۲). در مطالعه

زایتنفولگ^۱ و همکاران (۲۰۲۲)، دو مدل درخت تصمیم تقویت شده با گرادیان (XGBoost) و شبکه عصبی پیش‌خور (FNN)، برای پیش‌بینی هدایت هیدرولیکی اشباع (K_s) استفاده شدند. نتایج نشان داد که مدل XGBoost بهتر از FNN عملکرد داشته است. طی مطالعه‌ای لی^۲ و همکاران (۲۰۲۴)، XGBoost را به عنوان بهترین مدل برای پیش‌بینی درصد رطوبت بهینه با R^2 برابر با ۰/۹۲۳۴ گزارش دادند و RF نیز عملکرد خوبی در پیش‌بینی مقدار رطوبت داشت ($R^2 = 0.9198$, $RMSE = 1.3605$). در کل، نتایج اعتبارسنجی الگوریتم یادگیری ماشین نشان داد که مدل XGBoost برای مقاومت برشی و مقاومت فروری در سناریو ۲، که با شاخص‌های طیف‌سنجی، تصاویر ماهواره‌ای، سنجش از دور و داده‌های خاک ترکیب شده است، بهترین عملکرد را داشته است.

جدول ۲. نتایج اعتبارسنجی پیش‌بینی مکانی

پارامترهای اندازه‌گیری شده	الگوریتم‌های یادگیری ماشین	RMSE	R^2	MAE	nRMSE
مقاومت برشی	XGBoost	۳/۵۹	۰/۵۷	۲/۴۹	۰/۱۶
	RF	۳/۷۵	۰/۵۱	۲/۶۵	۰/۱۷
	KNN	۳/۸۴	۰/۴۹	۲/۵۳	۰/۱۷
مقاومت برشی (سناریو ۲)	XGBoost	۳/۶۱	۰/۶۱	۲/۳۴	۰/۱۶
	RF	۳/۶۵	۰/۵۷	۲/۳۴	۰/۱۶
	KNN	۳/۷۸	۰/۵۴	۲/۴۲	۰/۱۷
مقاومت فروری	XGBoost	۰/۴۷	۰/۵۳	۰/۲۷	۰/۱۵
	RF	۰/۴۴	۰/۵۳	۰/۲۸	۰/۱۴
	KNN	۰/۴۸	۰/۴۹	۰/۲۹	۰/۱۵
مقاومت فروری (سناریو ۲)	XGBoost	۰/۳۶	۰/۶۰	۰/۱۸	۰/۱۱
	RF	۰/۳۳	۰/۵۷	۰/۱۷	۰/۱۰
	KNN	۰/۴۹	۰/۵۵	۰/۲۹	۰/۱۵

۳-۳. انتخاب متغیرهای محیطی

بر اساس جدول ۳ از مجموع ۴۵ متغیر کمکی، ۱۰ متغیر محیطی با بیشترین میزان اهمیت بر اساس روش "جنگل تصادفی-حذف ویژگی برگشتی" 3(RF-RFE) انتخاب گردید. این متغیرها شامل چهار شاخص (Brightness, Greenness, Band 12, NDVI) حاصل از نسبت‌گیری باندهای ماهواره Sentinel 2 به دست آمده‌اند و شش پارامتر (CHNBL, PLC, WE, CHND, Valley depth, RSP) مستخرج از مدل رقومی ارتفاع انتخاب گردید. هفت پارامتر خاک شامل (بافت خاک (درصد رس، شن، سیلت)، کربن آلی خاک، آهن، جرم مخصوص ظاهری و میانگین هندسی قطر خاکدانه‌ها) نیز با ترکیب نظر کارشناس و حذف ویژگی برگشتی انتخاب شدند. طی پژوهشی نظری و همکاران (۲۰۲۰) نیز مشاهده شد که متغیرهای محیطی انتخاب شده توسط روش حذف ویژگی برگشتی (کاهش دقت میانگین تصادفی) دارای بالاترین سطح دقت در فرآیند نقشه‌برداری رقومی خاک بوده‌اند. تقی زاده و همکاران (۲۰۱۴) در مطالعه‌ای در دشت اردکان نتیجه گرفتند که پارامترهای حاصل از سنجش از دور دارای اهمیت بیشتری نسبت به فاکتورهای خاک‌سازی (ژئومورفولوژی، توپوگرافی و هدایت الکتریکی ظاهری خاک) در پیش‌بینی مکانی شوری خاک در افق‌های سطحی می‌باشند. علاوه بر این، جاکسیچ^۴ و همکاران (۲۰۲۱) نشان دادند که توپوگرافی، کاربری خاک و بافت خاک می‌توانند بر مقاومت برشی و فروری خاک‌ها تأثیرگذار باشند.

1 Zeitfogel

2 Li

3 Random Forest-Recursive Feature Elimination

4 Jakšić

بسالت‌پور^۱ و همکاران (۲۰۱۲) در مطالعه‌ای برای پیش‌بینی مقاومت برشی خاک سطحی از شبکه عصبی مصنوعی استفاده کردند و بیان داشتند که شاخص پوشش گیاهی یکی از مهم‌ترین پارامترها برای پیش‌بینی مقاومت برشی خاک می‌باشد. فان و سو^۲ (۲۰۰۸)، فرانتی^۳ و همکاران (۱۹۸۵)، و لئونارد و ریچارد^۴ (۲۰۰۴) نیز بیان کردند که پوشش گیاهی از طریق شبکه ریشه‌ای خود نقش بسیار مهمی در مقاومت برشی و پایداری خاک دارد. سطح پایه شبکه آبراهه^۵ تأثیر مهمی بر مقاومت برشی خاک دارد. افزایش رطوبت خاک در نزدیکی سطح پایه شبکه آبراهه، فرسایش و رسوب‌گذاری، تغییرات ساختار خاک و حضور ماده آلی، همگی می‌توانند به طور مستقیم یا غیرمستقیم بر مقاومت برشی خاک تأثیر بگذارند. جیانگ^۶ و همکاران (۲۰۲۱) در مطالعه‌ای در جنوب شرقی چین نشان داد که میزان رطوبت، جرم مخصوص ظاهری و میزان رس خاک تأثیری مستقیم بر مقاومت برشی و فروروی خاک دارند. همچنین، نتایج مطالعه هونگده^۷ و همکاران (۲۰۲۲) نشان دادند که مقدار رس خاک و مواد آلی تأثیری مستقیم بر مقاومت برشی خاک دارند و مدل‌های پیش‌بینی برای این پارامترها با دقت بالایی ایجاد شده‌اند. بر اساس جدول ۳، نتایج نشان می‌دهد که نمایندگان عوامل ساختاری خاک، از نظر فراوانی، سهم بیشتری نسبت به متغیرهای محیطی حاصل از داده‌های سنجش از دور داشته‌اند.

جدول ۳. متغیرهای انتخاب شده برای پیش‌بینی ویژگی‌های مکانیکی خاک مورد مطالعه

منبع	اختصار	پارامتر	فاکتور خاک‌سازی در مدل اسکورپین
DEM	Diffuse	Diffuse insulation شدت تابش پخشیده	توپوگرافی (r)
DEM	wetness	wetness index شاخص خیس	r
DEM	RSP	Relative. Slope.Position موقعیت نسبی شیب	r
DEM	CHND	Channel Network Distance فاصله تا شبکه آبراهه	r
DEM	VD	Valley depth (m) عمق دره	r
DEM	CHNBL	Channel network base level سطح پایه شبکه آبراهه	r
DEM	WE	Wind.Effect شاخص اثر باد	r-c
DEM	PLC	Plan curvature انحنای سطح	r
RS	NDVI	Normalized diff. vegetation index= $\frac{(NIR-RED)}{(NIR+RED)}$	ارگانیزم (O)
RS	Greenness	شاخص سبزیگی	O-S
RS	Brightness	شاخص روشنایی	S
RS	B12	باند ۱۲	
خاک (Soil)	CCE	آهک	
خاک (Soil)	GMD	میانگین هندسی قطر خاکدانه‌ها	
خاک (Soil)	BD (g.cm-3)	جرم مخصوص ظاهری	(S)
خاک (Soil)	Silt (%)	سیلت	
خاک (Soil)	SOC (%)	کربن آلی خاک	
خاک (Soil)	Sand (%)	شن	
خاک (Soil)	Clay (%)	رس	

1 Besalatpour

2 Fan and Su

3 Franti


4 Léonard and Richard

5 Chanel network base level (CHNBL)


6 Jiang

7 Hongde


اهمیت متغیرهای کمکی استفاده شده برای پیش‌بینی مقاومت برشی و مقاومت فروری در شکل ۴ نمایش داده شده است. متغیرهای اثر باد (WE)، سطح پایه شبکه آبراهه (CHNBL)، موقعیت نسبی شیب (RSP)، شاخص نرمال شده تفاوت پوشش گیاهی (NDVI)، بازتاب طیفی خاک (LT) و سیلت (Silt)، رس (Clay)، کربن آلی خاک (SOC)، جرم مخصوص ظاهری خاک (BD)، میانگین هندسی قطر خاکدانه‌ها (GMD) و کربنات کلسیم معادل (CCE) به عنوان پیش‌بینی کننده‌های مهم تعیین شدند. همچنین در مطالعه‌ای موسوی و همکاران (۲۰۲۱) پارامترهای توپوگرافی را از مهمترین پیش‌ران‌های محیطی برای مدل‌سازی تغییرات شوری در منطقه مورد مطالعه گزارش نمودند.



شکل ۳. اهمیت نسبی متغیرهای کمکی برای پیش‌بینی ویژگی‌های خاک



شکل ۴. توزیع مکانی مهم‌ترین متغیرهای کمکی انتخاب شده (الف) میانگین هندسی قطر خاکدانه‌ها (GMD)، (ب) کربن آلی خاک (SOC)



ادامه شکل ۴. پ) شاخص تفاضلی پوشش گیاهی نرمال‌شده (NDVI) ت) سطح پایه شبکه کانال (CHNBL)

۴-۳. تغییرپذیری مکانی

تغییرات مکانی ویژگی‌های مکانیکی خاک مانند مقاومت برشی و مقاومت فروروی خاک که توسط مدل درخت تصمیم تقویت شده با گرادیان (XGBoost) ارائه شده است، در شکل ۵ (الف) و (ب) نمایش داده شده است. همانطور که از شکل ۵ (الف) مشخص است، مقادیر بالای پیش‌بینی شده مقاومت برشی عمدتاً در بخش‌های شمال، غرب و شمال غربی و نواحی از جنوب غربی با استفاده از مدل درخت تصمیم تقویت شده با گرادیان نشان می‌دهد و به سمت نواحی مرکزی و جنوب و جنوب شرقی مقادیر مقاومت برشی بطور نامنظم کاهش می‌یابد که مقدار آن از ۶/۸۹ تا ۴۲/۶۸ کیلو پاسکال متغیر است. همچنین مقاومت فروروی در مناطق غربی، شمال غرب و در بخش‌هایی از نواحی شرق و جنوب شرقی افزایش را نشان می‌دهد و به سمت نواحی مرکزی و جنوب شرقی کاهش می‌یابد که مقدار آن از ۰/۷۵ تا ۶/۲۳ کیلو پاسکال متغیر است. با افزایش رطوبت، مقاومت برشی در هر یک از نقاط نمونه‌برداری به طور معنی‌داری کاهش می‌یابد (Zhang et al., 2023). طبق نتایج رضایی و طباطبایی (۲۰۱۹)، نیروهای چسبندگی سطحی بین ذرات آب و خاک ضعیف‌تر از نیروهای چسبندگی بین ذرات خاک است، بنابراین با افزایش رطوبت، مقاومت برشی خاک کاهش می‌یابد. کاهش مقاومت برشی در بخش مرکزی و جنوب شرقی منطقه به دلیل ویژگی‌های فیزیوگرافی تپه‌ای و کاربری مرتع است. این مناطق به طور خاص در معرض فرسایش شدید قرار دارند که ناشی از عوارض طبیعی و فعالیت‌های انسانی است (Virgo & Munro, 1978). در مقایسه با واحدهای دشت و دشت دامنه‌ای، این مناطق دارای خاک‌های سنگی و سنگریزه‌ای هستند که به افزایش فرسایش کمک می‌کند (Nguyen et al., 2023). همچنین، شسته شدن خاک در این نواحی به دلیل شیب‌های تند و کاهش پوشش گیاهی، به شدت افزایش یافته است. این عوامل به طور کلی منجر به کاهش مقاومت برشی و افزایش آسیب‌پذیری خاک در برابر فرسایش می‌شوند (Peele, 1938). شخم زدن مراتع عمدتاً در جهت شیب موجب تخریب ساختمان خاک شده و جریان‌های رواناب به راحتی ذرات ریز را از نواحی مرتفع به نواحی پایین‌تر منتقل می‌کند. در نتیجه، در مناطق بالادست به دلیل فرسایش خاک و تجمع سنگریزه‌ها، مقاومت برشی لایه سطحی کاهش می‌یابد و در مناطق پایین‌دست به دلیل تشکیل سله، این مقاومت افزایش پیدا می‌کند (Zhang et al., 2024). به نظر می‌رسد که پهنه‌بندی ماده آلی با

توجه به شکل (۴) در مناطقی که مقدار مقاومت برشی بیشتر است، افزایش یافته است. ماده آلی با بهبود ساختار خاک و ایجاد خاکدانه‌ها^۱ باعث افزایش پایداری و یکپارچگی خاک می‌شود که این بهبود ساختار باعث افزایش مقاومت برشی خاک می‌شود. ژانگ^۲ و همکاران (۲۰۱۵) نشان داد که اضافه کردن کودهای آلی به خاک باعث بهبود ساختار خاک و افزایش مقاومت برشی آن می‌شود. سایمون و کولی‌سون^۳ (۲۰۰۲) تأثیر تغییرات سطح پایه شبکه آبراهه و فرآیندهای فرسایش و رسوب‌گذاری بر پایداری خاک و مقاومت برشی آن را بررسی کردند. رابطه بین NDVI و مقاومت برشی خاک از طریق عوامل مختلفی مانند پوشش گیاهی، مواد آلی، رطوبت خاک و فرسایش قابل توضیح است. پوشش گیاهی متراکم و سالم، که دارای NDVI بالا است، می‌تواند به افزایش مقاومت برشی خاک از طریق بهبود ساختار خاک، افزایش مواد آلی و کاهش فرسایش کمک کند. مطالعه‌ای توسط دی باتس^۴ و همکاران (۲۰۰۹) انجام شد، این مطالعه تأثیر پوشش گیاهی بر مقاومت برشی خاک را بررسی کرد و نشان داد که حضور پوشش گیاهی متراکم می‌تواند به طور مستقیم به افزایش مقاومت برشی خاک کمک کند. پهنه‌بندی نقشه رقومی GMD با توجه به شکل (۴ الف) و مقاومت فروری خاک در شکل (۵) نشان می‌دهد که این ویژگی به طور مستقیم به اندازه ذرات، تراکم، رطوبت و ساختار خاک بستگی دارد. خاک‌های با خاکدانه‌های درشت‌تر و میانگین هندسی قطر خاکدانه‌ها (GMD) بزرگ‌تر معمولاً مقاومت فروری کمتری دارند، زیرا تداخل بین خاکدانه‌ای بیشتر است که باعث تسهیل در نفوذ ابزار می‌شود. با این حال، تراکم بیشتر یا کاهش رطوبت می‌تواند مقاومت فروری را افزایش دهد در مقابل، خاک‌های با ذرات خاکدانه ریزتر و GMD کوچک‌تر به دلیل تراکم بیشتر و فضای پوکی کمتر، مقاومت فروری بیشتری دارند (شکل ۵ ب). طی مطالعه‌ای دووچی^۵ و همکاران (۲۰۱۳) نشان دادند، افزایش تراکم و کاهش GMD منجر به افزایش مقاومت فروری خاک می‌شود. افزایش جرم مخصوص ظاهری خاک معمولاً سبب افزایش مقاومت برشی خاک همراه است همچنین افزایش مقدار رس خاک به افزایش چسبندگی و مقاومت برشی کمک می‌کند (Hongde et al., 2022). نتایج مطالعه سانتوس^۶ و همکاران (۲۰۲۱) نشان داد که مقاومت فروری خاک به طور مستقیم با جرم مخصوص ظاهری و محتوای رطوبت خاک مرتبط است این ارتباط قوی می‌تواند به عنوان ابزاری مؤثر برای پیش‌بینی رفتار مقاومت فروری خاک مورد استفاده قرار گیرد. مقاومت برشی و مقاومت فروری خاک به طور قابل توجهی تحت تأثیر متغیرهای مستقل مانند رطوبت، ماده آلی، میانگین هندسی قطر خاکدانه‌ها و پوشش گیاهی قرار دارند. همچنین، وجود ماده آلی در خاک می‌تواند تأثیرات متضادی داشته باشد، در حالی که در برخی شرایط، افزایش ماده آلی می‌تواند مقاومت برشی را کاهش دهد (Ekwue & Stone, 1998)، در شرایط دیگر ممکن است به بهبود ساختمان خاک و افزایش مقاومت کمک کند (Olu et al., 1986). پوشش گیاهی نیز با بهبود ویژگی‌های خاک، مانند افزایش حجم ریشه و کاهش فرسایش، می‌تواند به افزایش مقاومت فروری کمک کند. در نهایت، میانگین هندسی قطر خاکدانه‌ها نیز بر ویژگی‌های مکانیکی خاک تأثیرگذار است، زیرا توزیع اندازه ذرات می‌تواند بر تداخل و ظرفیت نگهداشت آب تأثیر بگذارد (Liu et al., 2021)، به‌طوری‌که با افزایش قطر ذرات، مقاومت برشی افزایش می‌یابد. این روابط پیچیده نشان‌دهنده تعاملات متنوع بین این متغیرها و تأثیر آن‌ها بر روی ویژگی‌های مکانیکی خاک است. با توجه به شکل (۵) در مناطق شمال غربی و همچنین در مناطق جنوبی و غرب، بین مقاومت برشی و مقاومت فروری خاک رابطه معکوس وجود دارد که تحت تأثیر عوامل مختلفی مانند مقدار رطوبت، نوع خاک و مدیریت خاک قرار می‌گیرد. نتایج سایر پژوهش‌ها نیز نشان می‌دهد که سیستم‌های خاک‌ورزی و مدیریت بقایای گیاهی می‌توانند به‌طور قابل‌توجهی بر مقاومت برشی و مقاومت فروری خاک تأثیر بگذارند (Ozlu et al., 2022; Ferreira et al., 2015).

1 Aggregates


2 zhang

3 Simon & Collison

4 De Baets

5 Deveci

6 Santos



شکل ۵. پراکنش مکانی الف) مقاومت برشی (SS) و ب) مقاومت فروروی (PR) با استفاده از مدل XGBoost

۴. نتیجه‌گیری کلی

مقاومت برشی و مقاومت فروروی از ویژگی‌های مهم مکانیکی خاک بوده که تأثیری مستقیم بر عملکرد و بهره‌وری آن دارند. با شناخت و مدیریت صحیح این ویژگی‌ها می‌توان بهره‌وری کشاورزی، مرتع را افزایش داد و از تخریب خاک جلوگیری کرد. استفاده از تکنیک‌های مناسب کشاورزی و مدیریت منابع می‌تواند به بهبود این ویژگی‌ها کمک کند. این تحقیق با هدف بررسی تغییرات مکانی رقومی دو ویژگی مکانیکی خاک شامل مقاومت برشی (SS) و مقاومت فروروی (PR) با استفاده از سه الگوریتم یادگیری ماشین (RF، XGBoost، و k-NN) در حوزه آبخیز کیلانه در استان کردستان انجام شد. نتایج صحت‌سنجی مدل‌ها نشان داد که مدل XGBoost در سناریو دوم مدل‌سازی بر اساس متغیرهای محیطی انتخاب‌شده، داده‌های طیفی و داده‌های خاک عملکرد بسیار خوبی در پیش‌بینی مقاومت برشی و مقاومت فروروی داشت. از بین متغیرهای انتخاب‌شده، ویژگی‌های خاک از جمله Clay، BD، SOC، Silt، GMD و ویژگی‌های توپوگرافی و سنجش از دور، به ویژه CHNBL و NDVI و داده‌های طیف‌سنجی در دامنه‌های مرئی - مادون قرمز نزدیک و میانی به عنوان عوامل موثر در پیش‌بینی ویژگی‌های مکانیکی خاک معرفی شدند. از میان این ویژگی‌ها، پارامترهای خاک بیشترین تأثیر را داشتند. نتایج این پژوهش نشان داد که هر سه مدل دارای توانایی بالایی برای پیش‌بینی ویژگی‌های مکانیکی خاک هستند. به طور کلی، نتایج این مطالعه نشان می‌دهد که به دلیل ماهیت زمان‌بر و پرهزینه بودن اندازه‌گیری مستقیم ویژگی‌های خاک و همچنین تغییرات مکانی زیاد آن‌ها، از ترکیب داده‌های طیف‌های Vis-NIR، متغیرهای محیطی و داده‌های زودیافت خاک (مانند بافت، جرم مخصوص ظاهری، ماده آلی) که با هزینه اندک قابل اندازه‌گیری بوده یا در بانک‌های اطلاعاتی موجود هستند، می‌توان برای نقشه‌برداری خاک در مقیاس حوزه آبخیز استفاده کرد. در پایان رویکرد مورد استفاده در این پژوهش دارای پتانسیل خوبی بوده و به عنوان یک الگو در تهیه نقشه‌های مدیریت‌پذیر خاک‌ها در مطالعات خاکشناسی توصیه می‌گردد.

سپاس‌گزاری

نویسندگان این مقاله از حوزه معاونت پژوهشی دانشگاه شهید چمران اهواز جهت تامین هزینه این تحقیق (قرارداد پژوهانه SCU.AS1.1401.97) تشکر و قدردانی می‌کند.

References

- Abdollahi, S., Delavar, M. A., & Shekari, P. (2013). Spatial distribution mapping of Pb, Zn and Cd and soil pollution assessment in Anguran area of Zanjan province. *Journal of Water and Soil*, (6), 1410-1420. <https://doi.org/10.22067/jsw.v0i0.19254>. (In Persian).
- Al-Adhadh, A. R., Abbas, B. J., & Ali, A. M. (2021, March). *Factors Influencing the Shear Strength of Clays: A review*. Materials Science and Engineering, 1st International Conference on Engineering Science and Technology (ICEST 2020) 23rd-24th December 2020, Samawah, Iraq.
- Alhai, D. P., Syakur, S., & Basri, H. (2021). Ketahanan Penetrasi Tanah pada Penggunaan Lahan Hortikultura di Saree Kabupaten Aceh Besar. *Jurnal Ilmiah Mahasiswa Pertanian*, 6(4), 680-690. <https://doi.org/10.17969/jimfp.v6i4.18350>.
- Asghari, Sh., Hasanpour Kashani, M., Shahab Arkhazloo, H. (2024). Modeling Soil Penetration Resistance Using Regression, Artificial Neural Network and Gene Expression Programming. *Journal of Water and Soil*. 38(2) 269-283. <https://doi.org/10.22067/jsw.2024.86792.1385>. (In Persian).
- Asghari, Sh., & Shahabi, M. (2019). Spatial variability of soil saturated hydraulic conductivity and penetration resistance in salt-affected lands around Lake Urmia. *Water and Soil*, 33(1), 103-116. <https://doi.org/10.22067/jsw.v33i1.74411>. (In Persian).
- Asgari, N., Ayoubi, S., Demattê, J. A. M. & Dotto, A. C. (2020). Carbonates and organic matter in soils characterized by reflected energy from 350–25000 nm wavelength. *Journal of Mountain Science*, 17(7), 1636-1651. <https://doi.org/10.1007/s11629-019-5789-9>.
- Asghari, Sh., Sheykhzadeh, G. R., & Shahabi, M. (2017). Geostatistical analysis of soil mechanical properties in Ardabil plain of Iran. *Archives of Agronomy and Soil Science*, 63(12), 1631-1643. <https://doi.org/10.1080/03650340.2017.1296136>.
- Babaeian, E., Homae, M., Vereecken, H., Montzka, C., Norouzi, A. A., van Genuchten, M. T. (2015). A comparative study of multiple approaches for predicting the soil–water retention curve: hyperspectral information vs. basic soil properties. *Soil Science Society of America Journal*, 79, 1043-8501. <https://doi.org/10.2136/sssaj2014.09.0355>.
- Bachmann, J., Contreras, K., Hartge, K. H., & MacDonald, R. (2006). Comparison of soil strength data obtained in situ with penetrometer and with vane shear test. *Soil and Tillage Research*, 87(1), 112-118. <https://doi.org/10.1016/j.still.2005.03.001>.
- Banaie, M. H. (1998). Soil moisture and temperature regimes map of Iran. *Soil and Water Research Institute*. Ministry of Agriculture, Tehran, Iran, 1sheet.
- Besalatpour, A., Hajabbasi, M. A., Ayoubi, S., Afyuni, M., Jalalian, A. & Schulin, R. (2012). Soil shear strength prediction using intelligent systems: artificial neural networks and an adaptive neuro-fuzzy inference system. *Soil science and plant nutrition*, 58(2), 149-160. <https://doi.org/10.1080/00380768.2012.661078>.
- Brevik, E. C., Cerdà, A., Mataix-Solera, J., Pereg, L., Quinton, J. N., Six, J., & Van Oost, K. (2015). The interdisciplinary nature of soil. *Soil*, 1(1), 117- 129. <https://doi.org/10.5194/soil-1-117-2015>, 2015.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32. <https://doi.org/10.1023/A:1010933404324>.
- Chen, T., & Guestrin, C. (2016). *Xgboost: A scalable tree boosting system*. In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining, San Francisco, California. USA.
- Davari, M., Karimi, S. A., Bahrami, H. A., Hossaini, S. M. A., Fahmideh, S. (2021). Simultaneous prediction of several soil properties related to engineering uses based on laboratory Vis-NIR reflectance spectroscopy. *Catena*. 197, 104987. <https://doi.org/10.1016/j.catena.2020.104987>.
- Demir, S., & Şahin, E. K. (2021). Assessment of feature selection for liquefaction prediction based on recursive feature elimination. *Avrupa Bilim ve Teknoloji Dergisi*, (28), 290-294. <https://doi.org/10.31590/ejosat.998033>.
- Deveci, E. R. D. E. M., Ozan, E., Kirpınar, I., Oral, M., DALOĞLU, A. G., Aydin, N., & ÖZTÜRK, A. (2013). Neurocognitive functioning in young high-risk offspring having a parent with bipolar I disorder. *Turkish Journal of Medical Sciences*, 43(1), 110-117. <https://doi.org/10.3906/sag-1205-78>.
- De Baets, S., Poesen, J., Gyssels, G., & Knapen, A. (2009). Effects of grass roots on the erodibility of topsoils during concentrated flow. *Geomorphology*, 76(1-2), 54-67. <https://doi.org/10.1016/j.geomorph.2005.10.002>.
- Ekwue, E. I., & Stone, R. J. (1995). Organic matter effects on the strength properties of compacted agricultural soils. *Transactions of the ASAE*, 38(2), 357-365.
- Fan C. C. & Su C. F. (2008). Role of roots in shear strength of root-reinforced soils and with high moisture content. *Ecological Engineering*. 33, 157–166. <https://doi.org/10.1016/j.ecoleng.2008.02.013>.

- Ferreira, F. B., Vieira, C. S., & Lopes, M. D. L. (2015). Direct shear behaviour of residual soil–geosynthetic interfaces–influence of soil moisture content, soil density and geosynthetic type. *Geosynthetics International*, 22(3), 257-272. <https://doi.org/10.1680/gein.15.00011>.
- Franti, T. G., Laflen, J. M. & Watson, D. A. (1985). Soil erodibility and critical shear under concentrated flow. *American Society of Agricultural Engineers*. 19, 85-2033.
- Gao, X. S., Yi, X. I. A. O., Deng, L. J., Li, Q. Q., Wang, C. Q., Bing, L. I., & Min, Z. E. N. G. (2019). Spatial variability of soil total nitrogen, phosphorus and potassium in Renshou County of Sichuan Basin. China. *Journal of Integrative Agriculture*, 18(2), 279–289. [https://doi.org/10.1016/S2095-3119\(18\)62069-6](https://doi.org/10.1016/S2095-3119(18)62069-6).
- Gomez, C., Philippe, L., & Guillaume, C. (2008). Continuum moval versus PLSR method for clay and calcium carbonate content estimation from laboratory and airborne hyperspectral measurements. *Geoderma*. 148, 14148. <https://doi.org/10.1016/j.geoderma.2008.09.016>.
- Havaee, Sh. Ayoubi, S. Mosaddeghi, M. R. (2014). Surface Shear Strength Modeling Using Soil and Environmental Attributes in Landscape Scale (Semirom District, Isfahan Province). *Journal of Water and Soil*. 28, 319-329. <https://doi.org/10.1016/j.geoderma.2008.09.016>. (In Persian).
- Hengl, T., Nussbaum, M., Wright, M. N., Heuvelink, G. B. M. (2018). Random forest as a generic framework for predictive modeling of spatial and spatio-temporal variables. *PeerJ*, 6, e5518. <https://doi.org/10.7287/peerj.preprints.26693v3>.
- Hongde, W., Dongli, S., Yipeng, Z., & Donghao, M. (2022). Unsaturated soil shear strength of agricultural soils influenced by reclamation sequences in coastal China. *European Journal of Soil Science*, 73(3), e13237. <https://doi.org/10.1111/ejss.13237>.
- Horn, R., & Smucker, A. J. M. (2005). Soil Compaction and Its Management. *In Soil Physical Measurement and Interpretation for Land Evaluation*. 125-146.
- Janik, L. J., Merry, R. H. Forrester, S. T. Lanyon D. M. Rawson. A. (2009). Rapid prediction of soil water retention using mid infrared spectroscopy. *Soil Science Society of America Journal*, 71(2), 507-514. <https://doi.org/10.2136/sssaj2005.0391>.
- Jakšić, S., Ninkov, J., Milić, S., Vasin, J., Živanov, M., Perović, V. & Komlen, V. (2021). Topographic position, land use and soil management effects on soil organic carbon (vineyard region of Niš, Serbia). *Agronomy*, 11(7), 1438. <https://doi.org/10.3390/agronomy11071438>.
- Jiang, Q., Cao, M., Wang, Y., Wang, J., & He, Z. (2021). Estimation of soil shear strength indicators using soil physical properties of paddy soils in the plastic state. *Applied Sciences*, 11(12), 5609. <https://doi.org/10.3390/app11125609>.
- Kang, J., Wei, J., Gan, F., & Li, J. (2021). Shear Strength of Purple Topsoil under Different Land Uses in the Three Gorges Reservoir Area, China. *Mountain Research and Development*, 41(3), R1. <https://doi.org/10.1659/MRD-JOURNAL-D-20-00081.1>.
- Karamooz, A., & Araghinejad, S. H. (2005). *Advanced hydrology, Industrial University of Amir Kabir (Poly Technics)*. Iran, Publication Centre of Amir Kabir University, Tehran.
- Khaledian, Y., & Miller, B. A. (2020). Selecting appropriate machine learning methods fordigital soil mapping. *Appl. Math Model*. 81, 401–418. <https://doi.org/10.1016/j.apm.2019.12.016>.
- Khayamim, F., Wetterlind, J., Khademi, H., Robertson, A. J., Cano, A. F. & Stenberg, B. (2015). Using visible and near infrared spectroscopy to estimate carbonates and gypsum in soils in arid and subhumid regions of Isfahan, Iran. *Journal of Near Infrared Spectroscopy*. 23(3), 155-165. <https://api.semanticscholar.org/CorpusID:15430731>.
- Khalil, M.B., Afyuni, M., Jalalian, A., Abbaspour, K.C., & Dehghani, A. A. (2011). Estimation surface soil shear strength by pedo-transfer functions and soil spatial prediction functions. *Water and Soil (Agricultural Sciences and Technology)*, 187–195. <https://doi.org/10.22067/jsw.v0i0.8520>. (In Persian).
- Kunakh, O., Zhukova, Y., Yakovenko, V., & Daniuk, O. (2022). Influence of plants on the spatial variability of soil penetration resistance. *Ekológia (Bratislava)*, 41(2), 113-125. <https://doi.org/10.2478/eko-2022-0012>.
- Khosravani, P., Moosavi, A., Baghernejad, M. (2021). Spatial Variations of Soil Penetration Resistance and Shear Strength and the Effect of Land Use Type and Physiographic Unit on These Characteristics. *Iranian journal of Soil and water research*. 52 (4), 1041-1057. (In Persian).
- Khosravani, P., Baghernejad, M., Moosavi, A. A. & Rezaei, M. (2023). Digital mapping and spatial modeling of some soil physical and mechanical properties in a semi-arid region of Iran. *Environmental Monitoring and Assessment*, 195(11), 1367. <https://doi.org/10.1007/s10661-023-11980-6>.
- Liu, X., Cheng, X., Wang, N., Meng, M., Jia, Z., Wang, J. & Zhang, J. (2021). Effects of vegetation type on soil shear strength in Fengyang Mountain Nature Reserve, China. *Forests*, 12(4), 490. <https://doi.org/10.3390/f12040490>.

- Leónard, J., & Richard, G. (2004). Estimation of runoff critical shear stress for soil erosion from soil shear strength. *Catena*, 57: 233–249. <https://www.researchgate.net/publication/223891102>.
- Li, H., Zhang, J., Yang, X., Ye, M., Jiang, W., Gong, J. & Xu, Z. (2024). Bayesian optimization based extreme gradient boosting and GPR time-frequency features for the recognition of moisture damage in asphalt pavement. *Construction and Building Materials*, 434, 136675. <https://doi.org/10.1016/j.conbuildmat.2024.136675>.
- Machado, T. D. A., Mendes, Í. N., Moraes, E. R. D., & Sousa, E. D. T. D. S. (2023). Modification of soil physical attributes as a function of subsoiling operations under different managements. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 27(4), 293-299. <https://doi.org/10.1590/1807-1929/agriambi.v27n4p293-299>.
- Mahmoudzadeh, H., Matinfar, H. R., Taghizadeh-Mehrjardi, R., & Kerry, R. (2020). Spatial prediction of soil organic carbon using machine learning techniques in western Iran. *Geoderma Regional*, 21, e00260. <https://doi.org/10.1016/j.geodrs.2020.e00260>.
- Matthew, W. (2011). Bias of the random forest out-of-bag (OOB) error for certain input parameters. *Open Journal of Statistics*, 2011. <https://www.researchgate.net/publication/275999921>.
- Mendes, W. D. S., Demattê, J. A. M., Barros, A. S. E., Salazar, D. F. U., & Amorim, M. T. A. (2020). Geostatistics or machine learning for mapping soil attributes and agricultural practices. *Revista Ceres*, 67(4), 330-336. <https://doi.org/10.1590/0034-737X202067040010>.
- Minasny, B., & McBratney, A. B. (2016). Digital soil mapping: A brief history and some lessons. *Geoderma*, 264, 301-311. <https://doi.org/10.1016/j.geoderma.2015.07.017>.
- Mousavi, S., Sarmadian, F., Omid, M., & Bogaert, P. (2021^a). Modeling the Vertical Soil Calcium Carbonate Equivalent Variation by Machine Learning Algorithms in Qazvin Plain. *Water and Soil*, 35(5), 719-734. <https://doi.org/10.22067/jsw.2021.71748.1076>.
- Mousavi, S. R., Sarmadian, F., Omid, M., & Bogaert, P. (2021^b). Digital Modeling of Three-Dimensional Soil Salinity Variation Using Machine Learning Algorithms in Arid and Semi-Arid lands of Qazvin Plain. *Iranian Journal of Soil and Water Research*, 52(7), 1915-1929. <https://doi.org/10.22059/ijswr.2021.323030.668957>. (In Persian).
- Mousavi, S. R., Sarmadian, F., Omid, M. (2022). Three-dimensional mapping of soil organic carbon using soil and environmental covariates in an arid and semi-arid region of Iran, Measurement. <https://doi.org/10.1016/j.measurement.2022.111706>.
- Momeni, E., He, B., Abdi, Y., & Armaghani, D. J. (2023). Novel Hybrid XGBoost Model to Forecast Soil Shear Strength Based on Some Soil Index Tests. *CMES-Computer Modeling in Engineering & Sciences*, 136(3). <https://doi.org/10.32604/cmcs.2023.026531>.
- Monroy-Rodríguez, F. L., Álvarez-Herrera, J. G., & Alvarado-Sanabria, Ó. H. (2017). Distribución espacial de algunas propiedades físicas del suelo en un transecto de la granja Tungaivita, Paipa. *Revista UDCA Actualidad & Divulgación Científica*, 20(1), 91-100. <https://doi.org/10.31910/rudca.v20.n1.2017.66>.
- Nazari, R., Ramezani Etedali, H., Nazari, B., & Collins, B. (2020). The impact of climate variability on water footprint components of rainfed wheat and barley in the Qazvin province of Iran. *Irrigation and Drainage*, 69(4), 826-843. <https://doi.org/10.1002/ird.2487>.
- Nguyen, T. T. (2021). Predicting agricultural soil carbon using machine learning. *Nature Reviews Earth & Environment*, 2(12), 825-825. <https://doi.org/10.1038/s43017-021-00243-y>.
- Nguyen, T.T., Tuyen, T.T., Sarzhanovna, A.T., Thuy, H. T., Luong, V. V., Du, T. D., & Khanh, V. T. (2023). Potential risks of soil erosion in North-Central Vietnam using remote sensing and GIS. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 27(11), 910-916. <https://doi.org/10.1590/1807-1929/agriambi.v27n11p910-916>.
- Ohu, J. O., Raghavan, G. S. V., McKyes, E., & Mehuys, G. (1986). Shear strength prediction of compacted soils with varying added organic matter contents. *Transactions of the ASAE*, 29(2), 351-355. <https://www.researchgate.net/publication/270613321>.
- Ozlu, E., Arriaga, F. J., Bilen, S., Gozukara, G., & Babur, E. (2022). Carbon footprint management by agricultural practices. *Biology*, 11(10), 1453. <https://doi.org/10.3390/biology11101453>.
- Padarian, J., Minasny, B., McBratney, A.B. (2020). Machine learning and soil sciences: a review aided by machine learning tools. *Soil*, 6(1), 35-52. <https://doi.org/10.5194/soil-6-35-2020>, 2020.
- Parsaie, F., Farrokhiyan Firouzi, A., Mousavi, S. R., Rahmani, A., Sedri, M. H., & Homae, M. (2021). Large-scale digital mapping of topsoil total nitrogen using machine learning models and associated uncertainty map. *Environmental Monitoring and Assessment*, 193, 1-15. <https://doi.org/10.1007/s10661-021-08947-w>.
- Peele, T. C. (1938). The relation of certain physical characteristics to the erodibility of soils. *Soil Science Society of America*, 2, 97-100. <https://doi.org/10.2136/sssaj1938.036159950002000C0015x>.
- Qin, N., Wang, K., Sun, H., Wang, D., & Wang, B. (2023). Forecasting the Mechanical Compaction Influence on Soybean Yield Using XGBoost, Available at SSRN, 28 Pages. <https://ssrn.com/abstract=4618322>.

- Rezaei, M., Mousavi, S. R., Rahmani, A., Zeraatpisheh, M., Rahmati, M., Pakparvar, M. & Cornelis, W. (2023). Incorporating machine learning models and remote sensing to assess the spatial distribution of saturated hydraulic conductivity in a light-textured soil. *Computers and Electronics in Agriculture*, 209, 107821. <http://hdl.handle.net/1854/LU-01H7SSJSEZYSS9DNXHB4FFF5R0>.
- Rezaei, M., & Tabatabai Klor R. (2019). Investigation of the effect of depth and moisture on soil shear strength in field and laboratory, 50 (2), 367-374.
- Schneider, W. E., & Young, R. (1997). Spectroradiometry methods. *Handbook of Applied Photometry*, ed. Casimer De Cusatis, 252.
- Shahabi, A., Nabiollahi, K., Davari, M., Zeraatpisheh, M., Heung, B., Scholten, T., Taghizadeh-Mehrjardi, R. (2022). Spatial prediction of soil properties through hybridized random forest model and combination of reflectance spectroscopy and environmental covariates. *Geocarto International*. 37(27): 18172–18195. <http://dx.doi.org/10.1080/10106049.2022.2138565>.
- Simon, A., & Collison, A. J. C. (2002). Quantifying the mechanical and hydrologic effects of riparian vegetation on streambank stability. *Earth Surface Processes and Landforms*, 27(5), 527-546. <https://doi.org/10.1002/esp.325>.
- Soil Science Society of America, (2008). *Glossary of Soil Science Terms* (pp. 18-77). Madison, Wis.
- Soil Survey Staff, (2022). *Keys to soil Taxonomy*. In: U.S. Department of Agriculture, Natural Resources Conservation Service, thirteenth ed. 18-77. Washington, DC.
- Santos, F.L., Jesus, V.A.M.D., & Valente, D.S.M. (2012). Modelagem da resistência à penetração do solo usando análises estatísticas e redes neurais artificiais. *Acta Scientiarum. Agronomy*, 34, 219-224. <https://doi.org/10.4025/actasciagron.v34i2.11627>.
- Sun, Z., Liu, F., Wang, D., Wu, H., & Zhang, G. (2023). Improving 3D Digital Soil Mapping Based on Spatialized Lab Soil Spectral Information. *Remote Sensing*, 15(21), 5228. <https://doi.org/10.3390/rs15215228>.
- Taghizadeh-Mehrjardi, R., Minasny, B., Sarmadian, F., Malone, B. P. (2014). Digital mapping of soil salinity in Ardakan region, central Iran. *Geoderma*, 213, 15–28. <https://doi.org/10.1016/j.geoderma.2013.07.020>.
- Taghizadeh-Mehrjardi, R., Schmidt, K., Toomanian, N., Heung, B., Behrens, T., Mosavi, A., Scholten, T. (2021). Improving the spatial prediction of soil salinity in arid regions using wavelet transformation and support vector regression models. *Geoderma*, 383, 1-21. <https://doi.org/10.1016/j.geoderma.2020.114793>.
- Virgo, K. J., & Munro, R. N. (1978). Soil and erosion features of the Central Plateau region of Tigray, Ethiopia. *Geoderma*, 20(2), 131-157. [https://doi.org/10.1016/0016-7061\(78\)90040-X](https://doi.org/10.1016/0016-7061(78)90040-X).
- Viscarra Rossel, R. A. V. (2008). ParLeS: Software for chemometric analysis of spectroscopic data. *Chemometrics and Intelligent Laboratory Systems*, 90, 72–83. <https://doi.org/10.1016/j.chemolab.2007.06.006>.
- Wilding, L. P., & Dress, L. R. (1983). In Application of geostatistics to spatial studies of soil. Eds. BB Trangmar, RS Yost and G Uehara. *Advances in Agr*, 38.
- Zeitfogel, H., Feigl, M., Schulz, K. (2022). Soil information on a regional scale: Two machine learning based approaches for predicting saturated hydraulic conductivity. *Geoderma*, 433, 116418. <https://doi.org/10.1016/j.geoderma.2023.116418>.
- Zhang, J., Wang, J., Zhao, N., Shi, J., & Wang, Y. (2024). Analysis of Changes in Runoff and Sediment Load and Their Attribution in the Kuye River Basin of the Middle Yellow River Based on the Slope Change Ratio of Cumulative Quantity Method. *Water*, 16(7), 944. <https://doi.org/10.3390/w16070944>.
- Zhang, Y., Lu, J., Han, W., Xiong, Y., & Qian, J. (2023). Effects of moisture and stone content on the shear strength characteristics of soil-rock mixture. *Materials*, 16(2), 567. <https://doi.org/10.3390/ma16020567>.
- Zhang, X., Xue, J., Chen, S., Wang, N., Shi, Z., Huang, Y., & Zhuo, Z. (2022). Digital mapping of soil organic carbon with machine learning in dryland of Northeast and North plain China. *Remote Sensing*, 14(10), 2504. <https://doi.org/10.3390/rs14102504>.
- Zhang, Y., Wang, F., Zhang, J., Zhu, T., Lin, C., Müller, C., & Cai, Z. (2015). Cattle manure and straw have contrasting effects on organic nitrogen mineralization pathways in a subtropical paddy soil. *Acta Agriculturae Scandinavica, Section B—Soil & Plant Science*, 65(7), 619-628. <https://doi.org/10.1080/09064710.2015.1039054>.
- Zhao, S., Ayoubi, S., Mousavi, S. R., Mireei, S. A., Shahpouri, F., Wu, S. X., ... & Tian, C. Y. (2024). Integrating proximal soil sensing data and environmental variables to enhance the prediction accuracy for soil salinity and sodicity in a region of Xinjiang Province, China. *Journal of Environmental Management*, 364, 121311. <https://doi.org/10.1016/j.jenvman.2024.121311>.
- Zhu, L., Liao, Q., Wang, Z., Chen, J., Chen, Z., Bian, Q., & Zhang, Q. (2022). Prediction of soil shear Strength parameters using combined data and different machine learning models. *Applied Sciences*, 12(10), 5100. <https://doi.org/10.3390/app12105100>.